

UNIVERSIDAD COMPLUTENSE DE MADRID
FACULTAD DE CIENCIAS ECONÓMICAS Y
EMPRESARIALES

Departamento de Fundamentos del Análisis Económico
II (Economía Cuántica)



DETECCIÓN DE COMPORTAMIENTOS PERIÓDICOS EN
COTIZACIONES DE ACCIONES DEL IBEX-35

MEMORIA PARA OPTAR AL GRADO DE DOCTOR
PRESENTADA POR

Concepción Díaz García

Bajo la dirección del doctor

Rafael Flores de Frutos

Madrid, 2013

**DETECCIÓN DE COMPORTAMIENTOS
PERIÓDICOS EN COTIZACIONES DE
ACCIONES DEL IBEX-35**

TESIS DOCTORAL

Concepción Díaz García

Director: Rafael Flores de Frutos

Departamento de Fundamentos del Análisis Económico II

Facultad de Ciencias Económicas y Empresariales

Universidad Complutense de Madrid

2012

A Kamal, mis Padres y Julián

Agradecimientos

La primera persona que me viene a la cabeza al pensar en “agradecimientos” es Rafael Flores de Frutos. Gracias por todo el apoyo, no solo académico y profesional, también personal. Gracias por esos “empujones” que han permitido que esta tesis se haya podido finalizar y por todo lo que he podido aprender de ti, no sólo en lo profesional, también en lo humano. Muchas gracias de corazón.

Por supuesto, tengo que agradecer a muchos de los profesores, que a lo largo de la licenciatura y cursos de doctorado, me han impartido clase. En especial a aquellos que me hicieron inclinarme por la especialidad de cuantitativa: Alfonso Novales, Luis Puch, Arthur B. Treadway, Jesús Ruiz, Teodosio Pérez, Emilio Cerdá, Covadonga de la Iglesia, Gregorio Serrano, Miguel Jerez, Iñigo Herguera y Cristina Mazón.

Quería mencionar de forma individual a Mercedes Gracia por su gran apoyo en el Colegio Universitario Cardenal Cisneros, fue un privilegio conocerte mejor.

Por supuesto, no me puedo olvidar de agradecer a Lola Robles y Juan Ángel Jiménez todos los comentarios y sugerencias que han mejorado esta tesis.

En estos momentos, recuerdo el inicio de este camino, y me vienen a la cabeza mis compañeros de doctorado. Cuantas risas y cuanto trabajo ha visto aquella sala de lectura convertida en nuestro despacho. Inolvidables esos momentos con Alfredo, Leonel, Rosana y Virginia. A éstos se unieron muchos más, que hicieron que las horas de trabajo se volvieran más llevaderas: Chelo, David, Eva, Gustavo, Nuño, Paco, Rafi, Teresa, Sonia Benito y Sonia Brajín. Imposible no recordar aquellas comidas

en el “Prefa”. No puedo dejar de dar las gracias a la que fuera mi compañera de despacho, Sonia de Lucas, por todo su apoyo y animo.

Muchas gracias a Manolo, sobre todo por toda la ayuda que me has brindado, y por leerte esta tesis antes que nadie. Es difícil imaginar un compañero mejor. Gracias también a Joaquín y Sofía, por interesarse siempre por la evolución de esta investigación. Por descontado, muchas gracias a mis “secres”, por animarme tanto en esas comidas y cafés.

Fuera del ámbito académico y profesional quiero dar las gracias a todos aquellos amigos que siempre se han interesado por este trabajo, aunque, en la mayoría de los casos, ni siquiera sabían en qué consistía. Gracias de todo corazón a Nuria, Jose, Carolina, Carlos, Bego. Por supuesto, a las más importantes, a mis Antonias, gracias chicas por estar siempre ahí.

Un recuerdo especial para Moni, en estos últimos meses, en que parece que estás apunto de alcanzar la meta pero que no llegas, recordarla me ha ayudado a dar ese último empujón que quedaba. Siempre estarás en mi corazón, mi ángel de la guarda.

No puedo olvidarme de mis padres y mi hermano. Gracias a mis padres porque lo que soy os lo debo a vosotros. Gracias por todo el apoyo incondicional y el amor que siempre me habéis dado. Gracias a Julián por ser mi confidente y sobre todo mi amigo.

Por último, gracias a Kamal. Literalmente, hemos recorrido este camino juntos, desde el primer día hasta el último. Espero que recorramos todos los caminos juntos. Gracias amor.

Índice general

1. Introducción	1
2. Revisión de la literatura	7
2.1. Introducción	7
2.2. Modelos periódicos	8
2.3. Modelos de cambio de régimen	14
2.4. Elección de una medida de precisión	23
2.A. Apéndice: Modelos periódicos	26
2.B. Apéndice: Contraste de estacionalidad univariante	29
2.C. Apéndice: Modelos de cambio de régimen	31
2.C.1. Modelo de regresión dinámica no lineal	31
2.C.2. Modelo de regresión de transición suave	31
2.C.3. Regresión cambiante y modelo autorregresivo de umbral	33
2.C.4. Modelo de ajuste de Markov	34
2.D. Apéndice: Criterios para seleccionar previsiones	35
3. Experimento I: Caso sin restringir	39
3.1. Introducción	39

3.2. Datos y Análisis univariante	40
3.3. Modelos Multivariantes	42
3.4. Contraste	43
3.5. Previsiones	45
3.6. Conclusiones	51
3.A. Apéndice: Descripción gráfica de las series	53
3.B. Apéndice: Estimación modelos VAR	57
3.B.1. IBEX-35	57
3.B.2. Abertis	60
3.B.3. ACS	64
3.B.4. Acerinox	67
3.B.5. Altadis	71
3.B.6. Acciona	74
3.B.7. BBVA	78
3.B.8. Bankinter	81
3.B.9. Banesto	85
3.B.10. Endesa	88
3.B.11. Enagas	92
3.B.12. FCC	95
3.B.13. Ferrovial	99
3.B.14. Gamesa	102
3.B.15. Gas Natural	106
3.B.16. Iberdrola	110
3.B.17. Iberia	114

3.B.18. Indra	117
3.B.19. Inditex	121
3.B.20. Metrovacesa	124
3.B.21. Banco Popular	128
3.B.22. Repsol	132
3.B.23. Banco Santander	135
3.B.24. Telefónica	139
3.B.25. Unión Fenosa	142
4. Experimento II: Caso restringido	147
4.1. Introducción	147
4.2. Estimación modelos VEC	148
4.3. Contraste	149
4.4. Previsiones	150
4.5. Conclusiones	156
4.A. Apéndice: Estimación modelos VEC	157
4.A.1. IBEX-35	157
4.A.2. Abertis	162
4.A.3. ACS	167
4.A.4. Acerinox	172
4.A.5. Altadis	177
4.A.6. Acciona	182
4.A.7. BBVA	187
4.A.8. Bankinter	192

4.A.9. Banesto	197
4.A.10. Endesa	202
4.A.11. Enagas	207
4.A.12. FCC	212
4.A.13. Ferrovial	217
4.A.14. Gamesa	222
4.A.15. Gas Natural	227
4.A.16. Iberdrola	232
4.A.17. Iberia	237
4.A.18. Indra	242
4.A.19. Inditex	247
4.A.20. Metrovacesa	252
4.A.21. Banco Popular	257
4.A.22. Repsol	262
4.A.23. Banco Santander	267
4.A.24. Telefónica	272
4.A.25. Unión Fenosa	277
 5. Conclusiones y Extensiones	 283
5.1. Conclusiones	283
5.2. Extensiones	286
 Bibliografía	 291

Indice de tablas

3.1. Estimación modelos univariantes	40
3.2. Resultado del contraste en Experimento I	44
3.3. Previsiones intramuestrales en Experimento I	45
3.4. Previsiones extramuestrales en Experimento I	47
3.5. Modelos compuestos en Experimento I	50
3.6. Contraste de Diebold-Mariano en Experimento I	51
3.7. IBEX-35: Elección del orden del VAR	57
3.8. IBEX-35: Estimación del VAR(1) ortogonalizado	58
3.9. IBEX-35: Función de correlación cruzada residual del VAR(1)	60
3.10. Abertis: Elección del orden del VAR	61
3.11. Abertis: Estimación del VAR(1) ortogonalizado	61
3.12. Abertis: Función de correlación cruzada residual del VAR(1)	62
3.13. ACS: Elección del orden del VAR	64
3.14. ACS: Estimación del VAR(1) ortogonalizado	65
3.15. ACS: Función de correlación cruzada residual del VAR(1)	67
3.16. Acerinox: Elección del orden del VAR	68
3.17. Acerinox: Estimación del VAR(1) ortogonalizado	68

3.18. Acerinox: Función de correlación cruzada residual del VAR(1)	69
3.19. Altadis: Elección del orden del VAR	71
3.20. Altadis: Estimación del VAR(1) ortogonalizado	72
3.21. Altadis: Función de correlación cruzada residual del VAR(1)	74
3.22. Acciona: Elección del orden del VAR	75
3.23. Acciona: Estimación del VAR(1) ortogonalizado	75
3.24. Acciona: Función de correlación cruzada residual del VAR(1)	76
3.25. BBVA: Elección del orden del VAR	78
3.26. BBVA: Estimación del VAR(1) ortogonalizado	79
3.27. BBVA: Función de correlación cruzada residual del VAR(1)	81
3.28. Bankinter: Elección del orden del VAR	82
3.29. Bankinter: Estimación del VAR(1) ortogonalizado	82
3.30. Bankinter: Función de correlación cruzada residual del VAR(1)	83
3.31. Banesto: Elección del orden del VAR	85
3.32. Banesto: Estimación del VAR(1) ortogonalizado	86
3.33. Banesto: Función de correlación cruzada residual del VAR(1)	88
3.34. Endesa: Elección del orden del VAR	89
3.35. Endesa: Estimación del VAR(1) ortogonalizado	89
3.36. Endesa: Función de correlación cruzada residual - Modelo VAR(1)	90
3.37. Enagas: Elección del orden del VAR	92
3.38. Enagas: Estimación del VAR(1) ortogonalizado	93
3.39. Enagas: Función de correlación cruzada residual del VAR(1)	95
3.40. FCC: Elección del orden del VAR	96
3.41. FCC: Estimación del VAR(1) ortogonalizado	96

3.42. FCC: Función de correlación cruzada residual del VAR(1)	97
3.43. Ferrovial: Elección del orden del VAR	99
3.44. Ferrovial: Estimación del VAR(1) ortogonalizado	100
3.45. Ferrovial: Función de correlación cruzada residual del VAR(1)	102
3.46. Gamesa: Elección del orden del VAR	103
3.47. Gamesa: Estimación del VAR(1) ortogonalizado	103
3.48. Gamesa: Función de correlación cruzada residual del VAR(1)	104
3.49. Gas Natural: Elección del orden del VAR	106
3.50. Gas Natural: Estimación del VAR(1) ortogonalizado	107
3.51. Gas Natural: Función de correlación cruzada residual del VAR(1)	108
3.52. Iberdrola: Elección del orden del VAR	110
3.53. Iberdrola: Estimación del VAR(1) ortogonalizado	111
3.54. Iberdrola: Función de correlación cruzada residual del VAR(1)	112
3.55. Iberia: Elección del orden del VAR	114
3.56. Iberia: Estimación del VAR(1) ortogonalizado	115
3.57. Iberia: Función de correlación cruzada residual del VAR(1)	117
3.58. Indra: Elección del orden del VAR	118
3.59. Indra: Estimación del VAR(1) ortogonalizado	118
3.60. Indra: Función de correlación cruzada residual del VAR(1)	119
3.61. Inditex: Elección del orden del VAR	121
3.62. Inditex: Estimación del VAR(1) ortogonalizado	122
3.63. Inditex: Función de correlación cruzada residual del VAR(1)	124
3.64. Metrovacesa: Elección del orden del VAR	125
3.65. Metrovacesa: Estimación del VAR(1) ortogonalizado	125

3.66. Metrovacesa: Función de correlación cruzada residual del VAR(1) . . .	128
3.67. Banco Popular: Elección del orden del VAR	129
3.68. Banco Popular: Estimación del VAR(1) ortogonalizado	129
3.69. Banco Popular: Función de correlación cruzada residual del VAR(1) .	130
3.70. Repsol: Elección del orden del VAR	132
3.71. Repsol: Estimación del VAR(1) ortogonalizado	133
3.72. Repsol: Función de correlación cruzada residual del VAR(1)	135
3.73. Banco Santander: Elección del orden del VAR	136
3.74. Banco Santander: Estimación del VAR(1) ortogonalizado	136
3.75. Banco Santander: Función de correlación cruzada residual del VAR(1)	137
3.76. Telefónica: Elección del orden del VAR	139
3.77. Telefónica: Estimación del VAR(1) ortogonalizado	140
3.78. Telefónica: Función de correlación cruzada residual del VAR(1)	142
3.79. Unión Fenosa: Elección del orden del VAR	143
3.80. Unión Fenosa: Estimación del VAR(1) ortogonalizado	143
3.81. Unión Fenosa: Función de correlación cruzada residual del VAR(1) . .	144
4.1. Resultado del contraste en Experimento II	149
4.2. Previsiones intramuestrales en Experimento II	151
4.3. Previsiones extramuestrales en Experimento II	153
4.4. Modelos compuestos en Experimento II	155
4.5. Contraste de Diebold-Mariano en Experimento II	156
4.6. IBEX-35: Test de cointegración, método de Engle-Granger	158
4.7. IBEX-35: Estimación del VEC(0)	159

4.8. IBEX-35: Función de correlación cruzada residual del VEC(0)	160
4.9. IBEX-35: Modelo VEC(0) ortogonalizado	162
4.10. Abertis: Test de cointegración, método de Engle-Granger	163
4.11. Abertis: Estimación del VEC(1)	164
4.12. Abertis: Función de correlación cruzada residual del VEC(1)	166
4.13. Abertis: Modelo VEC(1) ortogonalizado	167
4.14. ACS: Test de cointegración, método de Engle-Granger	167
4.15. ACS: Estimación del VEC(2)	169
4.16. ACS: Función de correlación cruzada residual del VEC(2)	171
4.17. ACS: Modelo VEC(2) ortogonalizado	172
4.18. Acerinox: Test de cointegración, método de Engle-Granger	173
4.19. Acerinox: Estimación del VEC(2)	174
4.20. Acerinox: Función de correlación cruzada residual del VEC(2)	176
4.21. Acerinox: Modelo VEC(2) ortogonalizado	177
4.22. Altadis: Test de cointegración, método de Engle-Granger	178
4.23. Altadis: Estimación del VEC(2)	179
4.24. Altadis: Función de correlación cruzada residual del VEC(2)	181
4.25. Altadis: Modelo VEC(2) ortogonalizado	182
4.26. Acciona: Test de cointegración, método de Engle-Granger	183
4.27. Acciona: Estimación del VEC(1)	184
4.28. Acciona: Función de correlación cruzada residual del VEC(1)	186
4.29. Acciona: Modelo VEC(1) ortogonalizado	187
4.30. BBVA: Test de cointegración, método de Engle-Granger	187
4.31. BBVA: Estimación del VEC(1)	189

4.32. BBVA: Función de correlación cruzada residual del VEC(1)	191
4.33. BBVA: Modelo VEC(1) ortogonalizado	192
4.34. Bankinter: Test de cointegración, método de Engle-Granger	192
4.35. Bankinter: Estimación del VEC(0)	194
4.36. Bankinter: Función de correlación cruzada residual del VEC(0)	196
4.37. Bankinter: Modelo VEC(0) ortogonalizado	197
4.38. Banesto: Test de cointegración, método de Engle-Granger	197
4.39. Banesto: Estimación del VEC(2)	199
4.40. Banesto: Función de correlación cruzada residual del VEC(2)	201
4.41. Banesto: Modelo VEC(2) ortogonalizado	202
4.42. Endesa: Test de cointegración, método de Engle-Granger	203
4.43. Endesa: Estimación del VEC(1)	204
4.44. Endesa: Función de correlación cruzada residual del VEC(1)	206
4.45. Endesa: Modelo VEC(1) ortogonalizado	207
4.46. Enagas: Test de cointegración, método de Engle-Granger	207
4.47. Enagas: Estimación del VEC(2)	209
4.48. Enagas: Función de correlación cruzada residual del VEC(2)	211
4.49. Enagas: Modelo VEC(2) ortogonalizado	212
4.50. FCC: Test de cointegración, método de Engle-Granger	213
4.51. FCC: Estimación del VEC(2)	214
4.52. FCC: Función de correlación cruzada residual del VEC(2)	216
4.53. FCC: Modelo VEC(2) ortogonalizado	217
4.54. Ferrovial: Test de cointegración, método de Engle-Granger	218
4.55. Ferrovial: Estimación del VEC(2)	219

4.56. Ferrovial: Función de correlación cruzada residual del VEC(2)	221
4.57. Ferrovial: Modelo VEC(2) ortogonalizado	222
4.58. Gamesa: Test de cointegración, método de Engle-Granger	223
4.59. Gamesa: Estimación del VEC(0)	224
4.60. Gamesa: Función de correlación cruzada residual del VEC(0)	226
4.61. Gamesa: Modelo VEC(0) ortogonalizado	227
4.62. Gas Natural: Test de cointegración, método de Engle-Granger	227
4.63. Gas Natural: Estimación del VEC(1)	229
4.64. Gas Natural: Función de correlación cruzada residual del VEC(1)	231
4.65. Gas Natural: Modelo VEC(1) ortogonalizado	232
4.66. Iberdrola: Test de cointegración, método de Engle-Granger	232
4.67. Iberdrola: Estimación del VEC(1)	234
4.68. Iberdrola: Función de correlación cruzada residual del VEC(1)	236
4.69. Iberdrola: Modelo VEC(1) ortogonalizado	237
4.70. Iberia: Test de cointegración, método de Engle-Granger	237
4.71. Iberia: Estimación del VEC(2)	239
4.72. Iberia: Función de correlación cruzada residual del VEC(2)	241
4.73. Iberia: Modelo VEC(2) ortogonalizado	242
4.74. Indra: Test de cointegración, método de Engle-Granger	243
4.75. Indra: Estimación del VEC(0)	244
4.76. Indra: Función de correlación cruzada residual del VEC(0)	246
4.77. Indra: Modelo VEC(0) ortogonalizado	247
4.78. Inditex: Test de cointegración, método de Engle-Granger	247
4.79. Inditex: Estimación del VEC(0)	249

4.80. Inditex: Función de correlación cruzada residual del VEC(0)	251
4.81. Inditex: Modelo VEC(0) ortogonalizado	252
4.82. Metrovacesa: Test de cointegración, método de Engle-Granger	252
4.83. Metrovacesa: Estimación del VEC(2)	254
4.84. Metrovacesa: Función de correlación cruzada residual del VEC(2)	256
4.85. Metrovacesa: Modelo VEC(2) ortogonalizado	257
4.86. Banco Popular: Test de cointegración, método de Engle-Granger	258
4.87. Banco Popular: Estimación del VEC(1)	259
4.88. Banco Popular: Función de correlación cruzada residual del VEC(1)	261
4.89. Banco Popular: Modelo VEC(1) ortogonalizado	262
4.90. Repsol: Test de cointegración, método de Engle-Granger	262
4.91. Repsol: Estimación del VEC(2)	264
4.92. Repsol: Función de correlación cruzada residual del VEC(2)	266
4.93. Repsol: Modelo VEC(2) ortogonalizado	267
4.94. Banco Santander: Test de cointegración, método de Engle-Granger	268
4.95. Banco Santander: Estimación del VEC(1)	269
4.96. Banco Santander: Función de correlación cruzada residual del VEC(1)	271
4.97. Banco Santander: Modelo VEC(1) ortogonalizado	272
4.98. Telefónica: Test de cointegración, método de Engle-Granger	272
4.99. Telefónica: Estimación del VEC(1)	274
4.100 Telefónica: Función de correlación cruzada residual - Modelo VEC(1)	276
4.101 Telefónica: Modelo VEC(1) ortogonalizado	277
4.102 Unión Fenosa: Test de cointegración, método de Engle-Granger	277
4.103 Unión Fenosa: Estimación del VEC(0)	279

4.104Unión Fenosa: Función de correlación cruzada residual - Modelo VEC(0)	281
4.105Unión Fenosa: Modelo VEC(0) ortogonalizado	282

Indice de Gráficos

3.1. Rendimientos de los valores	53
3.2. Cont: Rendimientos de los valores	54
3.3. Cont: Rendimientos de los valores	55
3.4. Cont: Rendimientos de los valores	56
3.5. IBEX-35: Residuos del VAR(1)	59
3.6. Abertis: Residuos del VAR(1)	63
3.7. ACS: Residuos del VAR(1)	66
3.8. Acerinox: Residuos del VAR(1)	70
3.9. Altadis: Residuos del VAR(1)	73
3.10. Acciona: Residuos del VAR(1)	77
3.11. BBVA: Residuos del VAR(1)	80
3.12. Bankinter: Residuos del VAR(1)	84
3.13. Banesto: Residuos del VAR(1)	87
3.14. Endesa: Residuos del modelo VAR	91
3.15. Enagas: Residuos del VAR(1)	94
3.16. FCC: Residuos del VAR(1)	98
3.17. Ferrovial: Residuos del VAR(1)	101

3.18. Gamesa: Residuos del VAR(1)	105
3.19. Gas Natural: Residuos del VAR(1)	109
3.20. Iberdrola: Residuos del VAR(1)	113
3.21. Iberia: Residuos del VAR(1)	116
3.22. Indra: Residuos del VAR(1)	120
3.23. Inditex: Residuos del VAR(1)	123
3.24. Metrovacesa: Residuos del VAR(1)	127
3.25. Banco Popular: Residuos del VAR(1)	131
3.26. Repsol: Residuos del VAR(1)	134
3.27. Banco Santander: Residuos del VAR(1)	138
3.28. Telefónica: Residuos del VAR(1)	141
3.29. Unión Fenosa: Residuos del VAR(1)	145
4.1. IBEX-35: Relaciones de cointegración	158
4.2. IBEX-35: Residuos del VEC(0)	161
4.3. Abertis: Relaciones de cointegración	163
4.4. Abertis: Residuos del VEC(1)	165
4.5. ACS: Relaciones de cointegración	168
4.6. ACS: Residuos del VEC(2)	170
4.7. Acerinox: Relaciones de cointegración	173
4.8. Acerinox: Residuos del VEC(2)	175
4.9. Altadis: Relaciones de cointegración	178
4.10. Altadis: Residuos del VEC(2)	180
4.11. Acciona: Relaciones de cointegración	183

4.12. Acciona: Residuos del VEC(1)	185
4.13. BBVA: Relaciones de cointegración	188
4.14. BBVA: Residuos del VEC(1)	190
4.15. Bankinter: Relaciones de cointegración	193
4.16. Bankinter: Residuos del VEC(0)	195
4.17. Banesto: Relaciones de cointegración	198
4.18. Banesto: Residuos del VEC(2)	200
4.19. Endesa: Relaciones de cointegración	203
4.20. Endesa: Residuos del VEC(1)	205
4.21. Enagas: Relaciones de cointegración	208
4.22. Enagas: Residuos del VEC(2)	210
4.23. FCC: Relaciones de cointegración	213
4.24. FCC: Residuos del VEC(2)	215
4.25. Ferrovial: Relaciones de cointegración	218
4.26. Ferrovial: Residuos del VEC(2)	220
4.27. Gamesa: Relaciones de cointegración	223
4.28. Gamesa: Residuos del VEC(0)	225
4.29. Gas Natural: Relaciones de cointegración	228
4.30. Gas Natural: Residuos del VEC(1)	230
4.31. Iberdrola: Relaciones de cointegración	233
4.32. Iberdrola: Residuos del VEC(1)	235
4.33. Iberia: Relaciones de cointegración	238
4.34. Iberia: Residuos del VEC(2)	240
4.35. Indra: Relaciones de cointegración	243

4.36. Indra: Residuos del VEC(0)	245
4.37. Inditex: Relaciones de cointegración	248
4.38. Inditex: Residuos del VEC(0)	250
4.39. Metrovacesa: Residuos de las relaciones de cointegración	253
4.40. Metrovacesa: Residuos del VEC(2)	255
4.41. Banco Popular: Relaciones de cointegración	258
4.42. Banco Popular: Residuos del VEC(1)	260
4.43. Repsol: Relaciones de cointegración	263
4.44. Repsol: Residuos del VEC(2)	265
4.45. Banco Santander: Relaciones de cointegración	268
4.46. Banco Santander: Residuos del VEC(1)	270
4.47. Telefónica: Relaciones de cointegración	273
4.48. Telefónica: Residuos del VEC(1)	275
4.49. Unión Fenosa: Relaciones de cointegración	278
4.50. Unión Fenosa: Residuos del VEC(0)	280

Abreviaturas

Lista de abreviaturas:

IBEX = IBEX-35

ABE = Abertis

ACX = Acerinox

ALT = Altadis

ANA = Acciona

BKT = Bankinter

BTO = Banesto

ELE = Endesa

ENG = Enagas

FER = Ferrovial

GAM = Gamesa

GAS = Gas Natural

IBE = Iberdrola

IBLA = Iberia

IDR = Indra

ITX = Inditex

MVC = Metrovacesa

POP = Banco Popular

REP = Repsol

SAN = Banco Santander

TEF = Telefónica

UNF = Unión Fenosa

l = lunes

m = martes

x = miércoles

j = jueves

v = viernes

Capítulo 1

Introducción

En esta tesis se estudia la presencia de comportamientos periódicos en un conjunto de series de la Bolsa de Madrid. Los modelos periódicos se caracterizan por dividir la serie en estaciones. Esto permite que los parámetros del modelo cambien de una estación a otra, y que shocks similares tengan diferentes efectos según el momento del año donde tengan lugar.

Los modelos periódicos se presentan como una alternativa a los modelos univariantes ARIMA, donde cada dato pasado recibe una ponderación que no varía en el tiempo.

Tiao y Grupe (1980) desarrollaron de forma teórica este tipo de modelos, pero no es hasta finales de los 80, cuando encuentran su aplicación en series económicas.

Osborn (1988) al estudiar el consumo trimestral de bienes duraderos del Reino Unido encuentra que esta serie tiene un comportamiento diferente al que presentan el ingreso, la riqueza y la inflación.

La autora justifica este hecho argumentando que la función de utilidad de los consumidores presenta estacionalidad, debido a que éstos cambian sus pautas de consumo a lo largo del año. Las pagas extraordinarias, las vacaciones estivales o las Navidades son ejemplos de los acontecimientos que están detrás de este comportamiento estacional.

Con objeto de aportar evidencia empírica a favor de su hipótesis, Osborn

ajusta un modelo periódico para el consumo donde se permite a los parámetros del modelo variar de un trimestre a otro. La autora encuentra que estas variaciones son significativas y persistentes a lo largo del tiempo.

Con el anterior trabajo queda demostrado, que el consumo de bienes duraderos del Reino Unido trimestral presenta comportamiento periódico, pero ¿existen más series donde se observe esta conducta?

Intentando responder la anterior pregunta, Franses y Romijn (1993) estudian 25 variables macroeconómicas trimestrales del Reino Unido. Para ello estiman un vector autorregresivo de corrección del error (VECM) que permite la presencia de relaciones de cointegración entre los distintos trimestres. Encuentran que en 17 de ellas, la dinámica que siguen las variables es más compleja que la que recoge un modelo autorregresivo (AR) con diferencias estacionales.

Todo lo anterior muestra que existen series temporales cuya dinámica se modeliza mejor utilizando especificaciones periódicas. El problema que surge es cómo detectar estos comportamientos de forma sencilla y eficiente.

Flores y Novales (1997) proponen un contraste para localizar comportamientos periódicos en series temporales. Los autores contrastan la hipótesis nula que el proceso generador de los datos es un modelo univariante, frente a la hipótesis alternativa de que es un modelo periódico.

Este contraste se construye con la varianza de los errores de previsión, por lo que al aplicarlo, se espera que seleccione aquel modelo que mejores previsiones obtiene dentro de la muestra. Sin embargo ¿será el modelo seleccionado el que mejores previsiones obtiene fuera de la muestra?

En esta tesis, siguiendo el trabajo de Flores y Novales (1997), se estudia si el contraste propuesto por estos autores es una herramienta válida para seleccionar aquel modelo que mejores previsiones extramuestrales consigue. Para ello se comprueba tanto el tamaño como la potencia del contraste.

Se han citado ejemplos de trabajos donde el modelo periódico ajusta mejor

los datos, sin embargo, a lo largo de la literatura se encuentran muchos trabajos donde estos modelos periódicos no prevén mejor que los univariantes fuera de la muestra.

En Novales y Flores (1997) los autores encuentran que los modelos periódicos prevén mejor que los univariantes cuando los primeros se restringen de forma adecuada. Además, observan que no siempre es un mismo modelo el que mejor prevé en todas las estaciones en las que se divide la serie. Esto es, para una misma serie, hay estaciones para las que prevé mejor el modelo periódico y otras para las que prevé mejor el univariante.

Este resultado abre la posibilidad de combinar ambos modelos para prever una única serie temporal. Esto es, usar modelos diferentes para prever cada una de las estaciones. Estos modelos compuestos se pueden ver como un tipo de modelos de cambio de régimen, en los que hay dos regímenes, uno el modelo univariante y otro el modelo periódico, y se cambia de un régimen a otro en función de un criterio determinado. La pregunta que surge de forma automática es ¿cómo decidir para cada estación, el modelo con el que se deben calcular las previsiones?

En esta tesis se propone un método sencillo. Se calcula la previsión extra-muestral para una estación concreta, usando el modelo que mejores previsiones intramuestrales haya tenido para esa estación. Si el modelo elegido es el correcto, es de esperar que el buen comportamiento predictivo dentro de la muestra se traslade a fuera de la muestra.

Este procedimiento de selección entre los dos regímenes, el univariante y el periódico, supone una ganancia frente a los modelos de cambio de régimen. Estos modelos tienen muy malos resultados en previsión debido a la dificultad para seleccionar el régimen correcto. En este trabajo se estudia si estos modelos compuestos consiguen mejores previsiones que los modelos univariantes y/o los modelos periódicos.

Para responder a todas estas cuestiones se eligen como objeto de estudio

series bursátiles. Más concretamente, la cotización máxima diaria del IBEX-35 y todos los componentes que formaron parte del índice para las fechas comprendidas entre el 05/01/2004 y el 29/06/2007.

La elección de estas series, permite generalizar un fenómeno que ha centrado la atención de un número importante de trabajos, el efecto día de la semana. Desde finales de los 80 se ha mostrado interés en estudiar este comportamiento, tanto en España como en otras bolsas extranjeras, encontrándose resultados que pueden sugerir la existencia de este efecto.

Si se centra la atención en el caso de España, varios autores han encontrado este fenómeno en la Bolsa española. Tal es el caso de Rubio (1991) y Martínez Abascal (1993).

Posteriormente, Peña (1995) señala que este efecto desaparece debido a la implantación de la Ley del Mercado de Valores, introducida a mediados de 1989. Este autor defiende que era la falta de eficiencia en el mercado lo que posibilitaba el efecto día de la semana. Sin embargo, en trabajos más recientes como el de Caceres et al. (2006) y el de García Blandón (2008), vuelve a presentarse este efecto, invalidando, en parte, las conclusiones del trabajo de Peña (1995).

Es por ello, que en esta tesis se ha propuesto buscar comportamientos periódicos a series de la Bolsa española. Mientras que en la mayor parte de la literatura del efecto día de la semana, se usan variables ficticias que dan como resultado diferentes rendimientos medios para cada día, en este trabajo, no sólo se va a permitir a cada día de la semana tener un rendimiento medio diferente, si no que se le va a permitir que tenga una dinámica diferente.

De esta manera, sobre estas series de la Bolsa de Madrid, se realizan dos experimentos. En un primer experimento se estima un modelo AR y un modelo periódico en forma de vector autorregresivo (VAR) ortogonalizado para cada una de las variables. Estos VAR se estiman para las series en niveles. Usando el contraste de Flores y Novales se selecciona para cada una de las variables cual es el modelo que

ha generado los datos con mayor probabilidad. Una vez seleccionados los modelos se comprueba si éstos son los que mejores previsiones consiguen. Además se estudia si un único modelo es el que mejor prevé para todos los días. Se construyen los modelos compuestos pertinentes y se comprueba la capacidad predictiva de éstos. Como medida de precisión de las previsiones se usa la raíz del error cuadrático medio (RECM).

Ante la sospecha de sobreparametrización de los modelos periódicos, se realiza un segundo experimento. Se estiman modelos periódicos en forma de VECM, donde las series son estacionarias. Esto permite realizar contrastes de significatividad individual sobre los parámetros del VECM, eliminando aquellos estadísticamente iguales a 0. Con estos modelos periódicos restringidos y los modelos AR estimados con anterioridad, se repiten los pasos del experimento anterior.

La tesis se organiza en cinco capítulos de la siguiente manera:

En el Capítulo 2, “Un repaso a la literatura”, aparecen los trabajos en los que se ha sustentado esta investigación. Se hace un recorrido por la evolución que han tenido los modelos periódicos a lo largo del tiempo, y las conclusiones a las que han llegado diferentes autores sobre su capacidad predictiva. Además, se presenta el contraste de estacionalidad que se usa como herramienta para discriminar entre el modelo univariante y el modelo periódico. También se hace un repaso a los diferentes modelos de cambio de régimen, sus diferentes aplicaciones y sus resultados en previsión. Por último, se hace una revisión de diferentes medidas de precisión para evaluar previsiones.

En el Capítulo 3, “Experimento I: caso sin restringir”, se presenta el análisis univariante de las 25 series objeto de estudio, y la estimación de los modelos VAR ortogonalizados para las series en niveles. Se calcula el contraste de estacionalidad y se computan las previsiones, para cada variable, con los modelos AR y periódicos. El capítulo concluye con la construcción de los modelos compuestos y la comprobación de su capacidad predictiva. En el apéndice de este capítulo se presenta un análisis

detallado y minucioso de la estimación de los modelos multivariantes para cada una de las variables objeto de estudio.

En el Capítulo 4, “Experimento II: caso restringido”, se estiman los modelos VECM, donde se eliminan aquellos parámetros que no son significativos. Se repite el cálculo del contraste y el estudio de la precisión predictiva. Para concluir, se construyen los modelos compuestos y se calculan sus previsiones. En el apéndice se analizan, de forma detallada, las relaciones de cointegración para cada una de las variables, así como la estimación de los modelos multivariantes.

En el Capítulo 5, “Conclusiones y Extensiones” se presentan las principales conclusiones y extensiones de esta tesis.

Capítulo 2

Revisión de la literatura

2.1 Introducción

En este capítulo se presenta una revisión de los diferentes temas abarcados en la tesis.

En una primera parte se hace un repaso a los modelos periódicos. Se revisa la literatura para situar en que momento se empezaron a aplicar estos modelos en economía. Se estudian los resultados que estos modelos han tenido en previsión.

En este apartado también se presenta el contraste de estacionalidad univariante, y se hace un breve repaso a la literatura del efecto día de la semana.

Ante el ejercicio que se hace en esta tesis de usar modelos diferentes para prever las diferentes estaciones de una misma variable, se presenta un repaso a los modelos de cambio de régimen. Se enumeran diferentes aplicaciones que se han realizado con ellos, y se estudian los resultados que han tenido en previsión.

Posteriormente se estudian diferentes medidas de precisión de las previsiones. A parte del tan utilizado error cuadrático medio (ECM), se repasan un conjunto de medidas usadas en la literatura, enumerando los problemas de calcular cada una de ellas.

En los diferentes apéndices con los que finaliza el capítulo, aparecen los desa-

rrolos teóricos de los modelos expuestos en cada una de las diferentes secciones.

2.2 Modelos periódicos

Tanto en la teoría económica, como al analizar los datos reales, el comportamiento de los agentes económicos muestra pautas estacionales. Este fenómeno se presenta tanto en series de consumo como en series de producción. La explicación de este comportamiento en las series de consumo se encuentra en la existencia de pagas extraordinarias, fiestas navideñas o vacaciones. Mientras que detrás de las de producción se encuentran los cierres de balance, la presentación de cuentas o el vencimiento de pagos.

Una forma de modelizar este tipo de comportamiento es a través de los modelos periódicos, los cuales permiten cambiar el valor de los parámetros en las diferentes estaciones en que está dividido el año. La forma teórica que tienen estos modelos aparece presentada en el Apéndice 2.A.

Las propiedades teóricas de los modelos periódicos ya aparecen en Tiao y Grupe (1980). Sin embargo, su aplicación al campo de la economía no fue inmediata. En el trabajo de Osborn et al. (1988), los autores quieren comprobar si existen relaciones de largo plazo entre las variables que intervienen dentro de la función de consumo de bienes no duraderos del Reino Unido. Al analizar las posibles relaciones de cointegración entre las variables, comparan la gráfica del consumo de bienes no duraderos con la del ingreso, y se percatan de que ambas tienen una tendencia creciente similar, pero que “los movimientos estacionales en el consumo son muy marcados y parecen no tener relación con las características estacionales del ingreso, la riqueza y la inflación”. Esto hace que los órdenes de integración del ingreso y del consumo difieran.

Buscando una explicación a este comportamiento diferente del consumo, Osborn (1988) plantea la idea de que los consumidores hacen diferentes elecciones de consumo a lo largo del año, lo que significa que la función de utilidad de los agentes

presenta estacionalidad. Para comprobar la estacionalidad de la función de utilidad identifica y modeliza un modelo periódico, donde los parámetros varían de un trimestre a otro, y encuentra que estas variaciones son significativas y persistentes a lo largo del tiempo.

Más adelante Osborn y Smith (1989) estudian si existe una mejora en las previsiones especificando modelos periódicos. Para este trabajo analizan tanto el agregado de consumo de bienes no duraderos trimestral en el Reino Unido, como 5 de sus componentes. Comparan la precisión de los modelos periódicos con modelos ARIMA univariantes convencionales. La conclusión a la que llegan es que no existe una gran mejora a la hora de prever el agregado usando el modelo periódico, pero sí que existe una mejora en el caso de los componentes.

Las conclusiones empíricas de este trabajo encuentran su respaldo teórico en Osborn (1991). Aquí la autora presenta los resultados teóricos de no identificar un modelo periódico cuando la serie presenta comportamiento estacional, concluyendo que se produce una pérdida de precisión en la previsión al usar un modelo ARIMA univariante subespecificado.

Hasta la fecha todas las aplicaciones de los modelos periódicos se habían hecho analizando series de consumo. En Franses y Romijn (1993) se amplía el tipo de series a las que se ajusta un modelo periódico. Se analizan 25 variables macroeconómicas trimestrales del Reino Unido, entre las que se encuentran series del consumo privado, el consumo público, la inversión, tanto pública como privada, las exportaciones y las importaciones, la fuerza de trabajo, la productividad, la masa monetaria, el tipo de interés y el tipo de cambio. Se ajustan modelos periódicos de corrección del error, cuya forma teórica se presenta en el Apéndice 2.A. En este trabajo se encuentra que en 17 de las 25 series estudiadas hay evidencia de que el proceso generador de los datos es un modelo periódico de corrección del error. Este resultado muestra que el comportamiento estacional es, en un gran número de casos, mucho más complejo que lo que se creía hasta ese momento, y que los modelos habituales usados en la literatura, donde no se permitía a los parámetros cambiar

entre estaciones, podían estar subespecificados. Este trabajo acaba indicando que si se modeliza este comportamiento periódico, es de esperar que haya ganancias en la previsión, al contar con un modelo que ajusta mejor los datos.

En el trabajo anterior, los autores obtienen que en 8 de los 25 casos no hay evidencia de que los parámetros del modelo cambien entre los diferentes trimestres. No se debe perder de vista que estos 8 casos se pueden considerar modelos periódicos donde los parámetros de las estaciones están restringidos a ser los mismos, y donde todos los trimestres reciben la misma perturbación aleatoria. Basándose en esta idea, Flores y Novales (1997) proponen un contraste de estacionalidad univariante. En este contraste la hipótesis nula es que el modelo que ha generado la serie es un proceso univariante, frente a la alternativa que considera que ha sido un modelo multivariante. Aplicando este contraste a 23 de las series anteriores, encuentran que en 8 de ellas el modelo univariante no será un caso restringido del periódico, facilitando una herramienta estadística que permita decidir cuando la estacionalidad presenta un comportamiento más complejo. El desarrollo teórico de este contraste aparecen en el Apéndice 2.B.

Ahora bien, cabe preguntarse si la estimación de estos modelos periódicos lleva a una mejor previsión que la que se obtiene con otros modelos más sencillos. Herwartz (1997) analiza series trimestrales de consumo e ingreso de Reino Unido, Alemania, Suecia y Japón, para estudiar la precisión de las previsiones realizadas con modelos periódicos. Para ello estima modelos autorregresivos no periódicos, y los compara con sus contrapartes periódicas. Los resultados que encuentra son dispares. Por un lado, los modelos periódicos obtienen mejores resultados en las previsiones ex-post. Sin embargo, los resultados de las previsiones ex-ante muestran que para todas las series de consumo y la de ingreso de Suecia, los modelos no periódicos tienen mejores resultados. En las series de ingreso de Japón, Reino Unido y Alemania, el modelo periódico es superior, tanto ex-ante como ex-post. Cuando se restringe el modelo periódico, todos los anteriores resultados se mantienen, salvo que para la serie del ingreso sueco, tanto ex-ante, como ex-post, ahora es más preciso el modelo

periódico.

Wells (1997b) estudia series de producto, consumo e inversión de la economía estadounidense. Llega a la conclusión de que el consumo y la inversión están coin-tegrados estacionalmente con el producto, indicando que estas variables comparten una tendencia estacional estocástica. Este trabajo se cuestiona la costumbre de tra-bajar con datos ajustados de estacionalidad, ya que este hábito puede impedir un mejor ajuste de los datos, y por tanto empeorar la precisión de las previsiones. Debi-do a este resultado, en Wells (1997a) se plantea especificar modelos con integración periódica como el desarrollado en Franses (1994). Aplica este tipo de modelos a 15 series macroeconómicas de Estados Unidos y lo compara con otros procedimientos no periódicos. Divide las series en dos bloques, uno con las 8 series de carácter finan-ciero y otro con las 7 restantes. De estas últimas, 5 de ellas presentan integración periódica, mientras que en el caso de las denominadas series de carácter financiero, los resultados son más ambiguos. Sin embargo, a la hora de realizar una compara-ción de las previsiones, no parece existir una mejora en la precisión al aplicar estos modelos periódicos.

Sobre las mismas series usadas por Wells (1997a) pero ampliadas a Reino Unido, Suecia, Alemania, Japón e Italia, Löf y Franses (2001) concluyen que los modelos donde las variables presentan diferencias estacionales tienen como resul-tado, generalmente, previsiones más precisas que aquellas realizadas con modelos periódicos.

Sin embargo, Novales y Flores (1997) sí encuentran que puede haber una ganancia en la previsión al aplicar modelos no periódicos. En este trabajo, los au-tores eligen las 17 series que Franses y Romijn (1993) encuentran que siguen un modelo periódico integrado y realizan un ejercicio de previsión para comprobar si existe alguna ganancia al usar estos modelos más complejos. Para ello comparan dos modelos univariantes donde los parámetros no cambian de un trimestre a otro, con cuatro modelos periódicos con diferentes tipos de restricciones. Estos autores encuentran que cuando no se restringen los modelos periódicos éstos no parecen pre-

ver mejor que los modelos con parámetros constantes entre trimestres. Sin embargo, al restringir apropiadamente los parámetros del modelo periódico éstos mejoran las previsiones.

Más recientemente, Rodrigues y Gouveia (2004) encuentran resultados similares a los de los anteriores autores. Analizando datos mensuales de ocupación hotelera de la región portuguesa del Algarve según la nacionalidad de los huéspedes, llegan a la conclusión de que los modelos periódicos ajustan bien estas variables, y cuando estos son convenientemente restringidos, se aprecian mejoras en la previsión frente a modelos autorregresivos univariantes en primeras diferencias.

Aunque los modelos periódicos no se han aplicado mucho a series bursátiles, hay muchos trabajos que defienden la presencia de comportamiento estacional en este tipo de variables. Toda la literatura referente al efecto fin de la semana trata de estudiar el diferente comportamiento de los agentes a lo largo de la semana, lo cual da como resultado diferentes rendimientos medios según el día.

Si se centra la atención en la Bolsa española, hay varios trabajos de principios de los noventa que defienden la existencia del efecto día de la semana.

Por citar sólo un par de ellos, Rubio (1991) encuentra que los lunes presentan un rendimiento medio superior y significativo para datos comprendidos entre 1984 y 1988. Lo mismo encuentra Martínez Abascal (1993) para datos entre 1985 y 1989. Esto contrasta con lo encontrado hasta la fecha en otros países, donde el rendimiento de los viernes tiende a ser más elevado, mientras que el rendimiento de los lunes tiende a ser anormalmente bajo.

Estos dos trabajos utilizan datos anteriores al 29 de julio de 1989. En esta fecha se introdujo la Ley del Mercado de Valores, momento en que comenzó a funcionar el mercado continuo.

En el trabajo de Peña (1994) se defiende que la introducción de las anteriores reformas eliminan el anterior efecto lunes. El autor llega a la conclusión que este efecto día de semana en la Bolsa española se debía a la falta de eficiencia del mercado.

Sin embargo, en trabajos más reciente, sí que aparece efecto día de la semana. Caceres et al (2006), introduciendo variables ficticias, tanto para explicar el rendimiento medio como la varianza condicionada, encuentran que el IBEX-35 tiene un comportamiento diferente los lunes y los jueves, con respecto al resto de la semana. Estudian valores comprendidos entre julio de 1997 y marzo de 2004.

Por su parte, García Blandón (2008) también encuentra efecto fin de semana, al introducir variables ficticias en una regresión que tiene como variable dependiente el rendimiento diario del IBEX-35. Este autor comprueba, analizando datos comprendidos entre enero de 1995 y mayo de 2006, que mientras el rendimiento de los lunes, martes, miércoles y jueves, no afecta de manera significativa al rendimiento del siguiente día, “el rendimiento del mercado durante el viernes, si afecta de manera importante al rendimiento del mercado del lunes siguiente”.

Por todo lo anterior, parece que hay varios trabajos en la literatura que defienden la existencia de comportamientos estacionales en series bursátiles españolas. Casi todos los trabajos analizados aquí se centran en regresiones donde se introducen variables ficticias. Sin embargo, se puede intentar otro tipo de aproximación al problema. Se puede estimar un modelo periódico que permita una dinámica diferente a cada día de la semana, de esta manera se puede identificar el efecto fin de semana encontrado en la literatura, y permitir la existencia de efectos en otros días de la semana.

Resumiendo, todos los trabajos anteriormente presentados parecen indicar que hay ciertas variables económicas cuya estacionalidad presenta un comportamiento complejo que puede modelizarse a través de los modelos periódicos. Sin embargo, aunque parece que estos modelos ajustan bien las series reales, no parece que exista unanimidad a la hora de justificar que su estimación conlleve una ganancia en la previsión. En uno de los primeros trabajos que analizan la precisión de los modelos periódicos, Osborn y Smith (1989) defienden su uso, ya que mejoran la capacidad predictiva. Hay autores como Novales y Flores (1997) y como Rodrigues y Gouveia (2004) que encuentran mejoras en la precisión de las previsiones, siempre

y cuando los modelos periódicos sean restringidos cuidadosamente. Por otro lado, Herwartz (1997) y Wells (1997b), no encuentran mejoras que justifiquen claramente la modelización más compleja de estos modelos periódicos.

Ahora bien si se busca una mejora en la previsión, quizá exista la posibilidad de usar un modelo diferente para cada una de las estaciones. Esto se puede entender como un modelo de cambio de régimen, donde uno de los estados es la modelización simple, y el otro, la modelización compleja. Ante esta perspectiva, en la siguiente sección se hace un repaso a la literatura de los modelos de cambio de régimen.

2.3 Modelos de cambio de régimen

Muchas series económicas, tanto financieras como reales, sufren grandes cambios en su comportamiento, asociados a crisis financieras o cambios importantes en las políticas gubernamentales. Esto hace que muchas variables económicas parezcan tener pautas diferentes en estos “períodos de cambio”, frente a las observadas a largo plazo. Este comportamiento estaría dando lugar a la necesidad de introducir modelos no lineales. Una forma de modelizar esto es a través de los modelos de cambio de régimen, que permiten variar la media poblacional condicionada y la varianza poblacional condicionada de acuerdo a un proceso estocástico.

Los modelos de cambio de régimen se dividen en dos grupos, según sea la variable que define la transición, s_t . Si es endógena, es decir, si hay retroalimentación entre la variable objeto de estudio y s_t , se tienen los modelos de regresión de transición suave (STR), autorregresivos de transición suave (STAR), autorregresivos de transición suave logarítmica (LSTAR), autorregresivos de transición suave exponencial (ESTAR) y autorregresivos de umbral (SETAR), entre otros. Si s_t es exógena, se tienen los modelos de ajuste de Markov.

En el Apéndice 2.C del final del capítulo se presentan de forma teórica los modelos de cambio de régimen más habituales. Aquí sólo se hace una descripción de sus usos y sus resultados en previsión.

Estos modelos de cambio de régimen han tenido muchas aplicaciones en la práctica. El modelo STR y modelo STAR se han usado para validar la hipótesis de la paridad del poder de compra. Sin embargo esta no ha sido su única aplicación. El modelo STAR se ha usado para modelizar asimetrías en variables macroeconómicas, como la producción industrial y la tasa de desempleo; y también se ha utilizado para representar no linealidades en la inflación. Por otro lado, el modelo STR se ha aplicado a modelizar la demanda de dinero, como aparece en Teräsvirta y Eliasson (2001), y a investigar la posible utilidad del diferencial de tipos de interés para prever la tasa de crecimiento, Paya et al. (2003).

El modelo SETAR, ha tenido aplicaciones similares al modelo STAR. Se ha utilizado para validar la paridad del poder de compra, y para modelizar asimetrías en los tipos de interés. Además, se han aplicado a la modelización del tipo de cambio, Henry et al. (2001).

El modelo conocido como momentum-TAR, desarrollado en Enders y Granger (1998), es un caso especial de modelo SETAR, y se ha utilizado para modelizar asimetrías en las tasas de crecimiento, es decir, para representar variables cuyo crecimiento es rápido (lento), pero su vuelta al nivel inicial es lento (rápido).

Por otro lado, los modelos de ajuste de Markov se han aplicado a situaciones donde existen varios regímenes, pero el cambio entre regímenes no es observable. Esto quiere decir que no existen datos para la variable que explica el cambio, o no es posible encontrar una variable proxy. Uno de los campos donde se ha aplicado este tipo de modelos es a la modelización de los tipos de interés bajo diferentes políticas monetarias.

En la literatura se encuentran diferentes trabajos que intentan explicar el comportamiento predictivo de los modelos de cambio de régimen. Teräsvirta y Anderson (1992) plantean que los modelos no lineales explican características de las variables que no se dan con mucha frecuencia. Si estas características no aparecen en el momento en el que se realiza la previsión, no existirá ningún tipo de ventaja

a la hora de usar los modelos de cambio de régimen en vez de modelos lineales más simples.

Otra razón por la que estos modelos fallan a la hora de prever puede ser porque el modelo no lineal sólo prevea mejor en alguno de los regímenes. Montgomery et al. (1998) prevén la tasa de desempleo trimestral estadounidense usando dos modelos diferentes de cambio de régimen y un modelo lineal autorregresivo. Estos autores comprueban que los modelos no lineales prevén mejor cuando el origen de la previsión se encuentra en un período de recesión, mientras que si se originan en un período de expansión la precisión del modelo lineal es mayor.

Una explicación diferente al mal rendimiento en previsión de los modelos de cambio de régimen se puede deber a que estos “sobreajustan”. Granger y Teräsvirta (1991) encuentran que cuando la evidencia de no linealidad es débil, los modelos no lineales “sobreajustan” el proceso y se ven peores resultados en la previsión. Es por ello, que la evidencia de no linealidad debe ser muy clara para plantearse la estimación de un modelo de cambio de régimen.

Por último, Dacco y Satchell (1999) se preguntan la razón por la que, aun sabiendo que un modelo no lineal es la mejor especificación, estos tienen peores resultados a la hora de prever que modelos mucho más sencillos, como por ejemplo un paseo aleatorio. Ellos comprueban que si hay el menor error a la hora de decidir en cual de los regímenes se haya la variable, el incremento en el ECM de los errores de previsión hace que sea más interesante usar modelos más simples. A esta misma conclusión llega Krolzig (2000), el cual encuentra que la capacidad predictiva del modelo no lineal muestra una dependencia muy fuerte de la correcta identificación del régimen en que se encuentra la variable en el momento de calcular la previsión.

En la literatura se encuentran gran número de trabajos que comparan la precisión de las previsiones de los modelos lineales frente a los modelos no lineales. Estos trabajos abarcan desde previsión de variables macroeconómicas, hasta rendimientos bursátiles, pasando por la modelización del tipo de cambio, y se han aplicado a series

de muy diferentes países. Se pasa ahora a repasar una muestra de esta literatura.

Clements y Krolzig (1998) comparan las previsiones hechas por un modelo SETAR y un modelo autorregresivo con ajuste de Markov, con autorregresivos lineales, para prever el PIB trimestral de Estados Unidos, usando datos posteriores a la Segunda Guerra Mundial. Comparan diferentes horizontes de previsión desde 1 trimestre a 16 trimestres. Un resultado interesante que hallan, que también aparece posteriormente en el trabajo de Stock y Watson (1999), es que las mejoras en las previsiones intramuestrales, sólo se trasladan fuera de ella si las características “no lineales” de la serie aparecen al final de la muestra. La conclusión a la que llegan es que para el PIB americano los modelos no lineales son superiores a los lineales recogiendo ciertas características del ciclo empresarial. Pero no es cierto que los modelos no lineales prevean siempre mejor que los lineales, para horizontes de previsión más cortos los modelos lineales se comportan mejor.

Un trabajo ampliamente citado es el de Stock y Watson (1999). Los autores usan 49 modelos de previsión diferentes para prever 215 series macroeconómicas estadounidenses mensuales. Dentro de estos modelos se incluyen modelos autorregresivos lineales, redes neuronales y modelos LSTAR. Construyen modelos según tres horizontes de previsión: 1, 6 y 12 meses. Las conclusiones no son muy halagüeñas: los modelos no lineales no lo hacen mejor que los lineales a un horizonte de previsión de 6 y 12 meses. Sí que se observa que lo hacen mejor a 1 mes, pero la mejora es pequeña, es decir, el incremento en la precisión no parece compensar el aumento de la complejidad a la hora de modelizar y estimar el modelo no lineal. Tanto es así, que los autores acaban recomendando el uso del modelo autorregresivo si sólo es posible usar un método de previsión.

En una revisión de las conclusiones del anterior trabajo, Teräsvirta et al. (2005) usan 47 series mensuales de los países del G7. La conclusión fundamental a la que llegan es la gran importancia que tiene una correcta modelización de los modelos no lineales para que se pueda hablar de ventajas a la hora de prever. En cuanto a la validación de la precisión de las previsiones, concluyen que los modelos LSTAR lo

hacen mejor que los lineales, algo que no queda claro al comparar las redes neuronales con los modelos lineales. Los autores se muestran ambiguos a la hora de recomendar la construcción de modelos no lineales, señalando que las ventajas de usar estos modelos dependen de lo grande que sea el coste de especificar cuidadosamente un modelo no lineal frente a la mejora de la previsión. Una crítica a este trabajo, que los propios autores señalan, es que sólo comprueban la precisión de las previsiones dentro de la muestra, mientras que no se preocupan en comprobar la precisión extramuestral, que es donde habitualmente fallan este tipo de modelos.

Siliverstovs y van Dijk (2003) prevén tasas de crecimiento de la producción industrial para los países del G7. Usan modelos autorregresivos lineales, estos mismos con cambios estructurales, modelos SETAR, modelos autorregresivos con ajuste de Markov, y comparan las ventajas predictivas de cada uno de ellos. Comparan que modelo es mejor a la hora de hacer una previsión puntual, una previsión por intervalos y una previsión de la distribución de probabilidad. La conclusión a la que llegan es que los modelos autorregresivos lineales son más precisos a la hora de hacer previsiones puntuales, tanto a horizontes de previsión largos como cortos. Mientras que el modelo autorregresivo con ajuste de Markov es más preciso en los otros dos casos, es decir, en las previsiones por intervalos y en las previsiones de la distribución de probabilidad. Esto significa que los modelos no lineales son más precisos a la hora de describir la incertidumbre alrededor de las realizaciones futuras de una serie temporal.

Los trabajos de Marcellino (2002),(2004) dentro del contexto de la Unión Europea también son interesantes. En Marcellino (2002) estudia 480 variables macroeconómicas de países de la zona euro. Compara modelos lineales (entre ellos autorregresivos lineales y paseos aleatorios) con modelos no lineales (como modelos STAR y redes neuronales). Estima 8 modelos diferentes en total y calcula previsiones para 1, 3 y 6 meses de horizonte de previsión. Los resultados le indican que para el 30 % de las series funcionan mejor los modelos no lineales. Es decir, si se dan no linealidades en el proceso generador de las series, entonces es factible esperar que

haya una mejora en previsión usando un modelo no lineal. En este mismo trabajo se estudian series de producción industrial, desempleo e inflación para los 11 países que originariamente formaron parte del Unión Monetaria Europea (UME). En el caso de las series de desempleo en el 50 % de los casos lo hacen mejor los modelos no lineales, y se consiguen resultados muy similares en el caso de la inflación. Una idea interesante que obtiene es la siguiente: en media los modelos lineales parecen superiores a los no lineales, porque estos últimos o lo hacen muy bien o lo hacen muy mal, por eso en media no suelen ser preferidos. Pero no se puede ignorar que en un 30 % de las series estudiadas por estos autores, los modelos no lineales lo hacen mejor que los lineales.

Siguiendo con su estudio anterior en Marcellino (2004) se prevén los agregados de las series, esto es, se plantea la idea de hacer previsiones para las series de la UME agregadas, en vez de hacer previsiones independientes para cada uno de los países. Al agregar las series se piensa que la serie resultante tendrá un comportamiento más suave y se ajustará mejor con modelos lineales al haber promediado los shocks de cada uno de los países. Pero en contra de esto se observa que la agregación introduce más no linealidades. Llega a la conclusión de que para un gran número de series la especificación no lineal es superior a la lineal, siendo por tanto mejor el resultado de los primeros modelos a la hora de prever. Sin embargo, en media, los modelos lineales no lo hacen del todo mal, por lo que habrá que sopesar si merece la pena mayor trabajo a la hora de construir un modelo no lineal.

Un campo donde parece plausible la aparición de no linealidades es la modelización del tipo de cambio. En Boero y Marrocu (2002) se encuentra un estudio sobre los capacidad predictiva de varios modelos para prever el tipo de cambio de tres monedas frente al dólar estadounidense. Para ello comparan el desempeño de los modelos SETAR, STAR y GARCH no lineales, con autorregresivos lineales. Usan datos mensuales y semanales. Los modelos SETAR son lo que mejor resultados obtienen tanto dentro como fuera de la muestra. Sin embargo cuando se computan previsiones puntuales y se calcula la precisión de la previsión por el ECM, no se

aprecian ganancias significativas al aplicar modelos no lineales. En cambio, cuando se hace el análisis sobre la densidad de probabilidad o se condicionan las previsiones a cada uno de los regímenes, entonces sí que existen ganancias importantes en previsión al usar los modelos no lineales. Esta última conclusión coincide con la encontrada por Siliverstovs y van Dijk (2003).

Dentro de esta área, Kilian y Taylor (2003) intentan explicar la incoherencia entre dos hechos: que los modelos económicos de tipo de cambio implican condiciones de largo plazo en las cuales se debe tener en cuenta la presencia de no linealidades, frente al hecho que es difícil batir al paseo aleatorio a la hora de realizar previsiones del tipo de cambio. Las razones que encuentran para explicar este hecho son: 1) habitualmente se comparan modelos lineales frente al paseo aleatorio, 2) aunque se usen modelos no lineales los datos disponibles para hacer previsión fuera de la muestra no son muchos (sólo se deberían usar datos post Bretton-Woods) y 3) la fortaleza de la unión entre las no linealidades de los tipo de cambio y los fundamentos de la economía se incrementa cuando aumenta la distancia entre el tipo de cambio observado y el de equilibrios. Los autores proponen un contraste estadístico que compara la precisión relativa de modelo ESTAR con un paseo aleatorio. Para ello usan datos de siete países y comparan su tipo de cambio frente al dólar estadounidense. La conclusión a la que llegan es que el modelo no lineal mejora las previsiones sobre todo a horizontes de previsión largos. Por ejemplo, cuando se usa un horizonte de previsión de tres años, el modelo no lineal mejora al paseo aleatorio, con un nivel del 90 % de confianza, en seis de los siete países. Sin embargo, las mejoras sólo se observan dentro de la muestra. Fuera de la muestra sólo en dos de los 7 casos mejora el modelo no lineal al paseo aleatorio.

Otro campo donde también se han buscado no linealidades en las variables es el de las finanzas. Aquí se puede señalar el trabajo de Bradley y Jansen (2004). Estos autores deciden modelizar los rendimientos bursátiles con modelos no lineales, debido a la presencia de grandes shocks en los mercados bursátiles. Proponen modelos que tengan dinámicas diferentes después de un shock. Buscan también una relación entre

los shocks bursátiles y el sector real, y prueban a comprobar si las no linealidades de los shocks se trasladan a la producción industrial. Para ello analizan la serie mensual del índice de producción industrial estadounidense y una serie mensual de lo que denominan exceso de rentabilidad del índice S&P500, medido como la variación porcentual del índice S&P500 menos el rendimiento mensual de los Bonos del Tesoro americanos a tres meses. Al exceso de rentabilidad del S&P500 le aplican un modelo lineal autorregresivo, un modelo LSTAR restringido y otro sin restringir, y un modelo de múltiples regímenes STAR. A la producción industrial se le ajustan los mismos modelos, salvo que sólo se estima un modelo LSTAR sin restringir. Adicionalmente se estima un modelo no lineal donde se incorpora la variable CDR (current depth of recession)¹. En su trabajo aparece un comportamiento ya visto con anterioridad: los modelos no lineales son superiores en previsión a los lineales dentro de la muestra, pero en cambio este resultado cambia al analizar la precisión de las previsiones extramuestrales. Los modelos lineales y el modelo con CDR se comportan de forma muy similar a la hora de predecir los rendimientos bursátiles, y ambos son mejores que los modelos no lineales. En cuanto a la producción industrial los modelos no lineales mejoran su comportamiento para hacerlo igual que los lineales, que lo hacen a su vez peor que el modelo con CDR.

En el trabajo de Bredin et al. (2008) se estudia la relación no lineal entre los rendimientos bursátiles y ciertas variables macroeconómicas como son: tipos de interés, tipo de cambio, inflación, producción industrial y cambios en el precio del petróleo, para seis países: Canada, Francia, Alemania, Japón, Reino Unido y Estados Unidos. Especifican un modelo STR para capturar esta relación y calculan previsiones un período hacia delante. Dentro de la muestra las previsiones realizadas por el modelo no lineal son las más precisas, mientras que fuera de la muestra el

¹ $CDR_t = \max\{Y_i\}_{i=1}^t - Y_t$, variable introducida por Beaudry y Koop (1993) donde Y es el nivel del producto. CDR toma el valor de 0 siempre y cuando el actual nivel de producto sea superior al nivel de producto que se alcanzó en el anterior pico. Por otro lado, CDR toma valor positivo durante la recesión, cuando el producto está cayendo, y durante el período que dure la recuperación, es decir, mientras el producto no alcance el nivel al que llegó en el anterior pico.

modelo no lineal es más preciso que el paseo aleatorio, pero su precisión a la hora de realizar previsiones puntuales es similar a la regresión lineal. Donde si se demuestra superior el modelo no lineal es en captar el signo del rendimiento, es decir si subirá la cotización o disminuirá con respecto al período anterior.

Uno de los resultados recurrentes en la literatura es el hecho que para muchos fenómenos económicos parece mucho más apropiado ajustar un modelo no lineal a uno lineal. De hecho, en gran multitud de los trabajos desarrollados en los anteriores párrafos, la precisión de los modelos no lineales dentro de la muestra es difícil de batir por los modelos lineales. Sin embargo, este buen resultado no suele reflejarse en la precisión de las previsiones fuera de la muestra. Es por ello que Enders y Pascualau (2010) proponen un contraste que indique de antemano si merecerá la pena estimar un modelo no lineal para obtener mejoras en la previsión extramuestral. Sus conclusiones son que cuando el contraste rechaza claramente la presencia de linealidad, el modelo no lineal mejora las previsiones fuera de la muestra del lineal. Los modelos que comparan son el autorregresivo simple con un modelo LSTAR y otro ESTAR. Las series que usan son series de tipo de cambio de diferentes países de la OCDE.

Resumiendo, parece que los modelos de cambio de régimen baten a los modelos lineales en las previsiones dentro de la muestra, pero parece que esto no se traslada a las previsiones extramuestrales. Esto ocurre aun cuando parece claro que la variable a analizar presenta no linealidades. Esto hace que se cuestione el uso de los modelos de cambio de régimen si el único objetivo es la previsión. No parece que la complejidad que lleva aparejada este tipo de modelos se traduzca en una mejora predictiva. Sin embargo muchos autores han intentado identificar las causas de este mal rendimiento de los modelos de cambio de régimen en previsión. Casi todos coinciden en señalar a la difícil identificación del régimen correcto como una de las causas principales de esta falta de precisión a la hora de prever.

Sin embargo, como indica Teräsvirta (2006) se tiene que señalar que uno de los problemas a la hora del desarrollo de estos modelos, es que hay muchos estudios

empíricos que buscan la comparación con los modelos lineales, y se echa en falta el desarrollo de una teoría que explique en profundidad estos modelos.

Para un estudio más detallado de este tipo de modelos revisar Teräsvirta (2006) y Hamilton (2008).

2.4 Elección de una medida de precisión

Si se trata de elegir entre diferente métodos de previsión, hay que fijar un criterio que permita escoger entre ellos. La lógica indica que se quiere tener el modelo que mejor prevea, pero para conseguir este fin se debe elegir algún instrumento para medir la precisión de las previsiones realizadas con cada uno de los modelos. El problema de lo anterior es que no todas las medidas de precisión usadas en la literatura de previsión dan una respuesta unánime. Esto es, según se fije una unidad de medida esto afecta a la decisión de que modelo usar para realizar la previsión.

La medida clásica usada en la literatura ha sido el ECM, o su raíz (RECM), habitualmente preferida a la primera porque está en las mismas unidades que los datos reales. La razón fundamental por la que se ha usado tan ampliamente esta medida de precisión es por su relevancia teórica desde el punto de vista estadístico. Sin embargo, enfrentado a los datos, Armstrong (2001) señala diferentes motivos por los que se debería tener en cuenta otra medida. La primera razón que argumenta es que una buena medida de precisión no debería verse afectada por la escala de los datos, algo que no ocurre con el ECM. En segundo lugar, a no ser que el estudio de los valores extremos sea parte del ejercicio de previsión, lo ideal sería contar con una medida que no se viera muy afectada por la presencia de los mismos. El ECM, al ser una medida basada en la media, puede verse muy afectada por la presencia de estos valores extremos, con lo cual podría ser interesante calcular una medida de precisión basada en la mediana en lugar de la media. Sin embargo, como el mismo Armstrong indica, a pesar de lo anterior el ECM es una medida muy usada en el ámbito académico.

Con anterioridad a este trabajo-resumen, Armstrong y Collopy (1992) comparan empíricamente seis medidas de precisión. Para ello usan una amplio número de series económicas de diferentes sectores y países (90 anuales y 101 trimestrales) y aplican 11 métodos de previsión diferentes, todos ellos explicados y desarrollados en Makridakis et al. (1982). Las seis medidas de precisión que analizan son: RECM, la media del error porcentual absoluto (MEPA), la mediana del error porcentual absoluto (MdEPA), la mediana del error relativo absoluto (MdERA), la media geométrica del error relativo absoluto (MGERA) y el mejor porcentaje (MP).

El autor señala que tanto MEPA como MdEPA, presentan tres inconvenientes. El primero es que estas medidas serían indefinidas si $y_{t+h} = 0$, y su distribución sería muy asimétrica cuando y_{t+h} tuviera valores muy próximos a 0. Esto hace que de forma habitual MEPA sea significativamente más grande que MdEPA. El segundo de los inconvenientes es que sólo sirven para datos escalados donde el 0 sea la magnitud de referencia. El tercer inconveniente es que penaliza más los errores de previsión positivos que los errores de previsión negativos, lo que influirá en la asimetría de la distribución. Esto hizo que Makridakis (1993) propusiera la media simétrica del error porcentual absoluto (sMEPA) y la mediana simétrica del error porcentual absoluto (sMdEPA), es decir las versiones simétricas de las anteriores.

Con estas medidas simétricas se corrige ligeramente el problema que surge con valores cercanos a 0. Sin embargo Koehler (2001) indica que estas medidas no son tan simétricas como su nombre puede indicar. De hecho para iguales valores de y_{t+h} , la sMEPA y la sMdEPA penalizan más las previsiones cuando superan al verdadero valor que cuando no lo alcanzan.

Las conclusiones a la que se llega en Armstrong y Collopy (1992) es que las mejores medidas para elegir el método de estimación son la MdERA o la MdEPA, las medidas de precisión basadas en la mediana. En cambio, para calibrar los parámetros de un modelo de previsión determinado, la mejor medida sería la MGERA.

Clements y Hendry (1993) notan que mientras que los modelos lineales son

invariantes a ciertos factores, los errores cuadráticos medios de las previsiones hechas por estos modelos no son invariantes. Es por ello que proponen una alternativa, el GFESM (General Forecast Error Second Moment Matriz), que se construye “apilando” los errores de previsión para cada uno de los horizontes de previsión. En el caso en que sólo se cuente con una previsión un período hacia delante, se tiene que GFESM=ECM. Una crítica a esta medida se puede encontrar en Armstrong y Fildes (1995).

En el Apéndice 2.D se presentan los desarrollos matemáticos de las medidas descritas con anterioridad.

Hasta el momento se ha hecho un repaso por ciertas medidas de precisión, pero la literatura se ha hecho eco de contrastes que comprueban si varias medidas de precisión son estadísticamente iguales.

Uno de los contrastes más utilizados en la literatura es el contraste de Diebold y Mariano (1995). Estos autores comprueban, que la diferencia de medias de dos funciones de pérdida de precisión, sigue una distribución normal. Bajo esta distribución construyen un contraste, donde la hipótesis nula es igualdad de las dos medidas de precisión.

Posteriormente, McCracken (2007) comprueba que si los modelos que se comparan están anidados, no es cierto que la distribución del estadístico anterior sea normal. Este autor obtiene los valores críticos para el contraste de Diebold y Mariano para modelos anidados, bajo ciertas condiciones. Estas condiciones son que la función de pérdida de la previsión, tiene que ser función de los errores de previsión, y los modelos que se comparan han tenido que ser estimados con mínimos cuadrados.

Aunque el contraste de Diebold y Mariano tiene gran relevancia en la literatura, se piensa que sus resultados pueden verse afectados por su falta de potencia. En Dell’Aquila y Ronchetti (2004), los autores ilustran con varios ejemplos esta característica del contraste.

En uno de los ejemplos obtienen series de errores de dos normales con dife-

rentes varianzas. El contraste debería rechazar la igualdad de precisión de las dos previsiones, sin embargo el contraste no la rechaza. Repitiendo el ejercicio, calculan que la potencia del contraste es del 27,2 % para 128 observaciones. Posteriormente, los autores introducen un valor extremo en una de las series de residuos, para conseguir artificialmente que las dos series de errores sean aun más diferentes, y de esa manera incrementar la tasa de rechazo del contraste, y comprueban que ocurre todo lo contrario. Con la introducción de valores atípicos, la potencia del contraste cae al 4,6 %.

Descubren que cuando las diferencias numéricas en los errores cuadráticos son muy pequeñas, un valor que sea lo suficiente diferente a los otros puede hacer que el contraste de Diebold y Mariano no se rechace todas las veces que se debiera.

2

2.A Apéndice: Modelos periódicos

Un modelo periódico se puede escribir como:

$$y_{Sn+s} = \sum_{j=1}^S [\mu_j + \tau_j(Sn + s)] D_{j,Sn+s} + x_{Sn+s} \quad (2.1)$$

$$x_{Sn+s} = \sum_{j=1}^S \sum_{i=1}^{p_j} \phi_{ij} D_{j,Sn+s} x_{Sn+s-i} + \varepsilon_{Sn+s} \quad (2.2)$$

donde S representa la periodicidad de los datos, mientras p_j es el orden del componente autorregresivo para la estación j , $p = \max(p_1, p_2, \dots, p_S)$, $D_{j,Sn+s}$ es una variable ficticia estacional que es igual a 1 en la estación j y cero en el resto de

²En otro de los ejemplos, tienen observaciones de dos distribuciones normales independientes, para las que la precisión predictiva es la misma. Añaden artificialmente valores extremos que hacen que las series cambien, y por tanto, se espera que el contraste señale que ambas previsiones no son iguales. Sin embargo, se encuentran con que la tasa de rechazo del contraste cae, en vez de incrementarse como se habría esperado. El contraste no detecta la diferencia entre las dos series. En el último ejemplo, comprueban la escasa potencia del contraste cuando la distribución tiene colas más grandes que la distribución normal.

casos, y $\varepsilon_{Sn+s} \sim iid(0, \sigma_S^2)$. El modelo representado en (2.1) y (2.2) requiere estimar $(3S + \sum_{j=1}^S p_j)$ parámetros.

El anterior proceso es no estacionario, ya que las varianzas y covarianzas pueden variar a lo largo del año según la estación, pero sí que sería estacionario para cada estación a lo largo de los años.

Sustituyendo (2.2) en (2.1), el modelo para la estación s es:

$$\phi_S(B)y_{Sn+s} = \phi_s(B) [\mu_s + \tau_s(Sn + s)] + \varepsilon_{Sn+s} \quad (2.3)$$

donde $\phi_j(B) = 1 - \phi_{1,j}B - \dots - \phi_{pj,j}B^{pj}$

Otra forma de representar el anterior modelo que facilita el paso a una versión multivariante es la siguiente. Sea Y_t una serie con periodicidad S , un proceso autorregresivo periódico de orden h , $PAR(h)$ se representa como:

$$Y_t = \sum_{s=1}^S \mu_s D_{st} + \sum_{j=1}^h \sum_{s=1}^S \phi_{js} D_{st} Y_{t-j} + \varepsilon_t \quad (2.4)$$

donde ε_t sigue un proceso ruido blanco, aunque seguramente con varianzas específicas para cada estación. D_{st} es una variable ficticia para cada una de las estaciones, siendo igual a 1 cuando Y_t es una observación de esa estación y 0 si lo es de las otras. El índice t varía desde 1 hasta $4N$, siendo N el número de años.

Aunque la representación (2.4) es la típica de un proceso periódico, se va a proponer una representación alternativa de Y_t , que surge de un VAR ortogonalizado para el vector de estaciones. Este vector de estaciones y_T , va a resultar de descomponer la serie anterior en S series, y_{sT} , una para cada estación, resultando: $y_T = (Y_{1T}, \dots, Y_{ST})$, donde cada componente de y_T sería una serie anual para una determinada estación.

El proceso $VAR(p)$ para y_T sería:

$$y_T = \delta + \Phi_1 y_{T-1} + \Phi_2 y_{T-2} + \dots + \Phi_p y_{T-p} + a_T \quad (2.5)$$

donde a_T es un proceso ruido blanco vectorial (4×1) , con matriz de varianzas y covarianzas Σ . La diagonalización de Σ tiene la forma de $A_0 \Sigma A_0' = \Lambda$, donde

A_0 es una matriz triangular inferior con unos en su diagonal principal. Esta matriz está definida de manera única y es consistente con la interpretación de la correlación contemporánea entre a_{iT} y a_{jT} , ($1 \leq i < j \leq S$), dos componentes cualesquiera de a_T , como los efectos dentro del año entre la estación i y la estación j . Los residuos pueden ser ortogonalizados premultiplicando (2.5) por A_0 :

$$A_0 y_T = \mu + A_1 y_{T-1} + \cdots + A_p y_{T-p} + \varepsilon_T \quad (2.6)$$

donde $A_j = A_0 \Phi_j$ para $j = 1, 2, \dots, p$, $\mu = A_0 \delta$ y $\varepsilon_T = A_0 a_T$, con $Var(\varepsilon_T) = \Lambda$, diagonal. Se va a denominar a (2.6) VAR(p) ortogonalizado.

Cualquier modelo PAR se puede escribir como un VAR ortogonalizado restringido. Por ejemplo, un PAR(1) se puede escribir como un VAR(1) ortogonalizado con la siguiente estructura:

$$A_0 = \begin{pmatrix} 1 & 0 & 0 & 0 \\ -\phi_2 & 1 & 0 & 0 \\ 0 & -\phi_3 & 1 & 0 \\ 0 & 0 & -\phi_4 & 1 \end{pmatrix} \quad \text{y} \quad A_1 = \begin{pmatrix} 0 & 0 & 0 & -\phi_1 \\ 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \\ 0 & 0 & 0 & 0 \end{pmatrix} \quad (2.7)$$

Lo contrario también es cierto, es decir, un VAR(p) ortogonalizado no restringido es un PAR(h) con $h \leq (p+1)s - 1$. La demostración de esto se encuentra en Tiao y Grupe (1980). Es por esto que el VAR(p) ortogonalizado y el PAR(h) pueden considerarse representaciones equivalentes del mismo proceso, por ello se denominan indistintamente modelos periódicos a ambos.

En un paso más avanzado del proceso se puede estudiar la presencia de cointegración entre las distintas estaciones. Bajo los supuestos de que todas las estaciones son al menos $I(1)$ y que sus niveles son generados por un proceso VAR(p), el número de relaciones de cointegración puede ser estudiado por Johansen y Juselius (1990) y Engle y Granger (1987). La presencia de relaciones de cointegración da como resultado el modelo de corrección del error:

$$\nabla y_T = \delta - B\alpha' y_{T-1} + \Gamma_1 \nabla y_{T-1} + \Gamma_2 \nabla y_{T-2} + \cdots + \Gamma_{p-1} \nabla y_{T-p+1} + a_T \quad (2.8)$$

donde $\nabla y_T = y_T - y_{T-1}$, las filas de la matriz α' de tamaño $(r \times s)$ son los r vectores de cointegración, y $Var(a_T) = \Sigma$.

De nuevo, si se diagonaliza Σ se puede obtener el modelo de corrección del error ortogonalizado:

$$A_0 \nabla y_T = \mu - (A_0 B) \alpha' y_{T-1} + A_0 \Gamma_1 \nabla y_{T-1} + A_0 \Gamma_2 \nabla y_{T-2} + \cdots + A_0 \Gamma_{p-1} \nabla y_{T-p+1} + \varepsilon_T \quad (2.9)$$

este es el modelo denominado por Franses y Romijn (1993) como modelo periódico de corrección del error. Se puede comprobar la significatividad de los coeficientes de (2.9) a través de un simple estadístico t .

Este es el tipo de modelo periódico que se especifica en el capítulo 4 de la presente tesis.

2.B Apéndice: Contraste de estacionalidad univariante

Para que los modelos anteriores puedan ser comparables a un modelo univariante se necesita homocedasticidad entre las estaciones, pero también que el comportamiento estadístico sea el mismo para todas las estaciones. Flores y Novales (1997) proponen un contraste de razón de verosimilitud que contrasta conjuntamente la homocedasticidad de los residuos ε con la validez de las restricciones que hay que imponer para que un proceso VAR estacional no sea más que un AR.

Bajo normalidad, si se tiene un modelo AR, la función soporte de verosimilitud restringida es:

$$\ln L_R = -\frac{ns}{2} \ln(2\pi) - \frac{ns}{2} \ln(\sigma_u^2) - \frac{1}{2\sigma_u^2} \sum_{j=1}^{ns} u_j^2 \quad (2.10)$$

donde u_j denota el error en un modelo univariante autorregresivo.

Si por el contrario, se tiene una representación multivariante, entonces suponiendo normalidad del vector de tamaño s de los residuos, se tiene la función soporte

de verosimilitud no restringida:

$$\ln L_{NR} = -\frac{ns}{2} \ln(2\pi) - \frac{ns}{2} \ln |\Sigma| - \frac{1}{2} \sum_{t=1}^n a_t' \Sigma^{-1} a_t \quad (2.11)$$

donde Σ es la matriz de covarianzas de tamaño $(s \times s)$ y a_t es el vector, con esperanza 0, de los residuos en t de las s estaciones. El valor de la función soporte de verosimilitud es invariante a las transformaciones lineales que transforman a_t en ε_t , por lo cual se puede usar tanto el VAR ortogonalizado como el no ortogonalizado para hacer el contraste.

La estimación máximo verosímil de u_j es:

$$\hat{\sigma}_u^2 = \frac{\sum_{j=1}^{ns} \hat{u}_j^2}{ns} \quad (2.12)$$

mientras que la estimación máximo verosímil para la matriz de varianzas Σ

$$\hat{\Sigma} = \frac{\sum_{t=1}^n \hat{a}_t \hat{a}_t'}{n} \quad (2.13)$$

lo que deja las expresiones (2.10) y (2.11) como:

$$\ln L_R = -\frac{ns}{2} \ln(2\pi) - \frac{ns}{2} \ln(\hat{\sigma}_u^2) - \frac{ns}{2} \quad (2.14)$$

$$\ln L_{NR} = -\frac{ns}{2} \ln(2\pi) - \frac{ns}{2} \ln |\hat{\Sigma}| - \frac{ns}{2} \quad (2.15)$$

así que el contraste de razón de verosimilitud para comprobar si un modelo univariante estacional ARIMA es una versión restringida de una representación multivariante VAR, consiste en comprobar la significatividad del estadístico:

$$\lambda = -2 (\ln L_R - \ln L_{NR}) = n \left\{ s \ln \left(\frac{1}{ns} \sum_{j=1}^{ns} \hat{u}_j^2 \right) - \ln \left| \frac{1}{n} \sum_{t=1}^n \hat{a}_t \hat{a}_t' \right| \right\} \quad (2.16)$$

Este contraste se basa en el desarrollado por Lütkepolt (1993) para contrastar varianzas y coeficientes que varían en el tiempo en un modelo PAR. Como en aquel, este contraste sigue una distribución asintótica χ^2 con J grados de libertad, donde J tiene la forma:

$$J = (s-1)(ps+2) + \frac{s(s-1)}{2} = (s-1) \left\{ s \left(p + \frac{1}{2} \right) + 2 \right\} \quad (2.17)$$

2.C Apéndice: Modelos de cambio de régimen

Los modelos de cambio de régimen son una aplicación práctica de los modelos no lineales. El proceso generador de datos se entiende como lineal, pero va cambiando de un régimen a otro en base a algún tipo de regla.

Los primeros modelos que se presentan en esta sección consideran que el cambio de un régimen a otro se realiza a través de una variable de transición, s_t , endógena, es decir, que existe “feedback” entre la variable objeto de estudio, y_t , y s_t .

El último modelo presentado, el modelo de ajuste de Markov, considera que s_t es exógena, por lo que no existirá ningún tipo de retroalimentación entre y_t y s_t .

2.C.1 Modelo de regresión dinámica no lineal

Un modelo general de regresión dinámica no lineal puede definirse como:

$$y_t = f(\mathbf{z}_t; \theta) + \varepsilon_t \quad (2.18)$$

donde $\mathbf{z}_t = (\mathbf{w}_t', \mathbf{x}_t')$ es un vector de variables explicativas, $\mathbf{w}_t = (1, y_{t-1}, \dots, y_{t-p})'$ y $\mathbf{x}_t = (x_{1t}, \dots, x_{kt})'$ vector de variables exógenas. Además, $\varepsilon_t \sim iid(0, \sigma^2)$, y se supone que y_t es estacionaria.

Los modelos que se van a desarrollar a lo largo de esta sección son casos particulares del modelo 2.18.

2.C.2 Modelo de regresión de transición suave

El modelo de regresión de transición suave (STR: smooth transition regression model) aparece en el trabajo de Bacon y Watts (1971). Estos autores consideran dos líneas de regresión y desarrollan un modelo en el que la transición de una línea a otra es suave. Ellos utilizaron la función hiperbólica para caracterizar esta transición. En

general este modelo STR se define como:

$$y_t = \phi' \mathbf{z}_t + \theta' \mathbf{z}_t G(\gamma, \mathbf{c}, s_t) + \varepsilon_t \quad (2.19)$$

donde \mathbf{z}_t viene definido como en (2.18), $\phi = (\phi_0, \phi_1, \dots, \phi_m)'$ y $\theta = (\theta_0, \theta_1, \dots, \theta_m)'$ son vectores de parámetros, y $\varepsilon_t \sim iid(0, \sigma^2)$. $G(\gamma, \mathbf{c}, s_t)$ es la función de transición, donde γ es un parámetro que representa la pendiente, y $\mathbf{c} = (c_1, c_2, \dots, c_K)'$, es un vector de parámetros de localización, $c_1 \leq c_2 \leq \dots \leq c_K$. La función de transición es una función acotada de la variable s_t , siendo continua para cualquier valor de s_t .

Si se usa la función logística como función de transición se tiene:

$$G(\gamma, \mathbf{c}, s_t) = \left(1 + \exp \left\{ -\gamma \prod_{k=1}^K (s_t - c_k) \right\} \right)^{-1}, \quad \gamma > 0 \quad (2.20)$$

La ecuación (2.19) junto con la (2.20) definen el modelo de regresión de transición suave logístico (LSTR). Los valores más comunes de K son $K = 1$ y $K = 2$. Para $K = 1$, los parámetros $\phi' + \theta G(\gamma, \mathbf{c}, s_t)$, cambian monótonamente como función de s_t desde ϕ a $\phi + \phi\theta$. A este modelo se le denomina LSTR1. Cuando $K = 2$, los parámetros cambian de forma simétrica alrededor de $(c_1 + c_2)/2$, donde esta función logística alcanza su valor mínimo. Este modelos se denomina LSTR2.

Una variación del modelo LSTR2 es el modelo de regresión de transición suave exponencial (ESTR), modelo en el cual la función de transición es:

$$G(\gamma, c, s_t) = 1 - \exp \{ -\gamma (s_t - c)^2 \}, \quad \gamma > 0 \quad (2.21)$$

esta función de transición es una aproximación a (2.20) con $K = 2$ y $c_1 = c_2$.

La variable de transición s_t es una variable estocástica, y generalmente un elemento de \mathbf{z}_t . Cuando \mathbf{x}_t no aparece en (2.19) y $s_t = y_{t-d}$ ó $s_t = \Delta y_{t-d}$, el modelo STR se convierte en el modelo autorregresivo de transición suave (STAR: smooth transition autoregressive model). Según la función de transición utilizada en el modelo STAR, se puede tener el modelo ESTAR, cuando la función es la exponencial, o el modelo LSTAR, cuando se utiliza la logística.

2.C.3 Regresión cambiante y modelo autorregresivo de umbral

Otro modelo de cambio de régimen son las regresiones cambiantes (SR: switching regression), que son lineales por tramos y tienen la forma general de:

$$y_t = \sum_{j=1}^{r+1} (\phi_j' \mathbf{z}_t + \varepsilon_{jt}) \mathbf{I}(c_{j-1} < s_t \leq c_j) \quad (2.22)$$

donde $\mathbf{z}_t = (\mathbf{w}_t', \mathbf{x}_t')'$ tiene la misma forma que en (2.18), s_t es una variable aleatoria continua que marca el cambio de régimen, c_0, c_1, \dots, c_{r+1} son parámetros que marcan el umbral para el cambio, $c_0 = -\infty$, $c_{r+1} = +\infty$. Además, $\varepsilon_{jt} \sim iid(0, \sigma_j^2)$, $j = 1, 2, \dots, r$. $\mathbf{I}(c_{j-1} < s_t \leq c_j)$ es una función indicador, que tomará valor 1 cuando sucede $c_{j-1} < s_t \leq c_j$ y 0 en caso contrario.

El modelo (2.22) es un modelo lineal por tramos, donde en general, los puntos de cambio entre tramos son desconocidos. Una alternativa bastante popular en la literatura es un modelo como el anterior pero con sólo dos regímenes:

$$y_t = (\phi_1' \mathbf{z}_t + \varepsilon_{1t}) \mathbf{I}(s_t \leq c_1) + (\phi_2' \mathbf{z}_t + \varepsilon_{2t}) \{1 - \mathbf{I}(s_t \leq c_1)\} \quad (2.23)$$

Notar que este modelo es un caso especial de (2.19) con $K = 1$ en (2.20).

Cuando no hay presencia de \mathbf{x}_t y $s_t = y_{t-d}$, con $d > 0$, entonces (2.22) se convierte en un modelo autorregresivo de umbral SETAR (self-exciting threshold autoregressive). Un modelo SETAR con dos regímenes es un caso especial de LSTAR1 cuando $\gamma \rightarrow \infty$.

Enders y Granger (1998) sugirieron un caso especial del modelo SETAR, consistente en dos regímenes y con $s_t = \Delta y_{t-d}$. Este modelo es conocido como momentum-TAR (momentum threshold autoregressive).

2.C.4 Modelo de ajuste de Markov

En el modelo (2.22), la variable que define el cambio, s_t , es una variable continua observable. Si esta variable fuera no observable y pudiera tomar un número finito de valores discretos, además de ser independiente de y_t para todos los retardos, se tendría un modelo autorregresivo de ajuste de Markov del tipo:

$$y_t = \sum_{j=1}^r \alpha_j' \mathbf{z}_t \mathbf{I}(s_t = j) + \varepsilon_t \quad (2.24)$$

donde s_t sigue una cadena de Markov, generalmente de orden 1. Si el orden es igual a 1, la probabilidad condicional del evento $s_t = i$ dado s_{t-k} , $k = 1, 2, \dots$, depende sólo de s_{t-1} y es igual a:

$$p_{ij} = P(s_t = i | s_{t-1} = j) \quad , \quad i, j = 1, \dots, r \quad (2.25)$$

tal que $\sum_{i=1}^r p_{ij} = 1$. Las probabilidades de transición no son conocidas y deben ser estimadas. El error ε_t se supone que no depende del régimen ni del valor de s_t .

Hamilton (1989) propone un modelo autorregresivo de ajuste de Markov (Markov-switching autoregressive model) muy común en diferentes aplicaciones econométricas. En este modelo, la constante varía en función del valor de la variable latente s_t y sus retardos. La forma de este modelo es:

$$y_t = \mu_{s_t} + \sum_{j=1}^p \alpha_j (y_{t-j} - \mu_{s_{t-j}}) + \varepsilon_t \quad (2.26)$$

donde el comportamiento de s_t viene definido por (2.25), y $\mu_{s_t} = \mu^{(i)}$ para $s_t = i$, tal que $\mu^{(i)} \neq \mu^{(j)}$, $i \neq j$. Por otro lado, y_{t-j} y $\mu_{s_{t-j}}$ en (2.26) comparten el mismo coeficiente α_j por razones de identificación.

2.D Apéndice: Criterios para seleccionar previsiones

En la literatura aparecen muchos trabajos que quieren comparar la capacidad predictiva de diferentes modelos. Sin embargo, la decisión de que modelo prevé mejor depende de la medida de precisión que se elija para valorar esas previsiones. En esta sección se hace un repaso a diferentes medidas que han aparecido en la literatura.

Sea y_{t+h} el dato real en el momento $t + h$ y sea $f_t(h)$ la previsión de y_{t+h} realizada en el momento t con un horizonte de previsión h . Se define el error de previsión como $e_{t+h} = y_{t+h} - f_t(h)$.

La medida clásica usada en la literatura ha sido el ECM:

$$ECM = \frac{\sum_{n=1}^N (e_{t+h})^2}{N} \quad (2.27)$$

o su raíz (RECM), habitualmente preferida a (2.27) porque está en las mismas unidades que los datos reales .

Tanto el ECM como el RECM son medidas de error absoluto, por lo que puede ser conveniente calcular medidas de error relativas. Así se puede calcular la media del error porcentual absoluto (MEPA) y la mediana del error porcentual absoluto (MdEPA). En estas medidas se relativiza el error de previsión al verdadero valor de la variable.

Para calcular tanto la MEPA como la MdEPA se define el error porcentual absoluto (p_{t+h}) como:

$$p_{t+h} = 100 \cdot \left| \frac{e_{t+h}}{y_{t+h}} \right| \quad (2.28)$$

la MEPA se halla calculando la media aritmética de los errores porcentuales. Mientras que para calcular la MdEPA, se calcula la mediana de los errores porcentuales.

Un inconveniente que presentan estas dos últimas medidas es que penalizan más los errores de previsión positivos que los errores de previsión negativos, lo que

influye en la asimetría de la distribución. Esto hizo que Makridakis (1993) propusiera las sMEPA y la sMdEPA, es decir, las versiones “simétricas” de las anteriores. Los errores porcentuales “simétricos” tendrán la forma:

$$s_{t+h} = 200 \cdot \frac{|e_{t+h}|}{(y_{t+h} + f_{t+h})} \quad (2.29)$$

Con estas medidas se corrige ligeramente el problema que surge con valores cercanos a 0. Sin embargo Koehler (2001) indica que estas medidas no son tan “simétricas” como su nombre pudiera indicar. De hecho, para iguales valores de y_{t+h} , el valor (2.29) penaliza más las previsiones cuando superan al verdadero valor que cuando no lo alcanzan.

Otras medidas relativas son la media geométrica del error relativo absoluto (MGERA) y la mediana del error relativo absoluto (MdERA). Para obtenerlas se debe calcular antes el error relativo absoluto (r_{t+h}):

$$r_{t+h} = \left| \frac{e_{t+h}}{e_{t+h}^*} \right| \quad (2.30)$$

donde e_{t+h}^* es el error de previsión obtenido al usar un modelo de previsión de control, generalmente un paseo aleatorio. Con los errores calculados según (2.30) sólo resta calcular la mediana y la media geométrica para obtener las anteriores medidas de precisión. Un inconveniente serio de estas medidas sería los casos en que e_{t+h}^* sea pequeño. Para solucionar esto, Armstrong y Collopy (1992) proponen “winsorizar” r_{t+h} de la siguiente manera:

$$wr_{t+h} = \begin{cases} 0,01 & \text{si } r_{t+h} < 0,01 \\ r_{t+h} & \text{si } 0,01 \leq r_{t+h} \leq 10 \\ 10 & \text{si } r_{t+h} > 10 \end{cases} \quad (2.31)$$

así se asegura que e_{t+h}^* nunca sea demasiado pequeño.

Clements y Hendry (1993) notan que mientras que los modelos lineales son invariantes a ciertos factores, los errores cuadráticos medios de las previsiones hechas por estos modelos no son invariantes. Es por ello que proponen una alternativa, el

GFESM (General Forecast Error Second Moment Matriz), que se construye “apilando” los errores de previsión para cada uno de los horizontes de previsión de la siguiente manera:

$$|\phi_h = |E[EE']|$$

donde

$$E' = [e'_{t+1}, e'_{t+2}, \dots, e'_{t+h-1}, e'_{t+h}]$$

en el caso en que sólo se cuente con una previsión un período hacia delante, se tiene que GFESM=ECM. Una crítica a esta medida se puede encontrar en Armstrong y Fildes (1995).

Hyndman y Koehler (2005) proponen la media del error escalado absoluto (MEEA). En ella, escalan los errores basándose en el error absoluto medio cometido por un paseo aleatorio dentro de la muestra, de la siguiente manera:

$$q_{t+h} = \frac{e_{t+h}}{\frac{1}{N-1} \sum_{i=2}^N |e_i^*|} \quad (2.32)$$

q_t será menor que 1 cuando los errores provengan de un modelo que prevé mejor que un paseo aleatorio, y será mayor que 1 en caso contrario. Con estos errores escalados se calcula la media.

Hassani et al. (2009), proponen un ratio de la raíz del error cuadrático medio *RRMSE*:

$$RRMSE = \frac{\left(\sum_{i=1}^N (\hat{y}_{T+h,i} - y_{T+h,i})^2 \right)^{\frac{1}{2}}}{\left(\sum_{i=1}^N (\tilde{y}_{T+h,i} - y_{T+h,i})^2 \right)^{\frac{1}{2}}} \quad (2.33)$$

donde \hat{y}_{T+h} es la previsión h períodos hacia delante obtenidos por el modelo univariante y \tilde{y}_{T+h} es la previsión h períodos hacia delante obtenidos por el modelo multivariante. De tal modo que si $RRMSE > 1$, el modelo univariante prevé peor que el multivariante.

Por último, una forma sencilla de determinar que modelo obtiene mejores previsiones es calculando el mejor porcentaje (MP). Para calcularlo se define la variable ficticia:

$$j_{t+h} = \begin{cases} 1 & \text{si } |e_{t+h}| < |e_{t+h}^*| \\ 0 & \text{en caso contrario} \end{cases} \quad (2.34)$$

y con (2.34) se calcula $MP = \frac{\sum_{i=1}^N j_{t+h,i}}{N}$. De esta manera se elige el modelo cuyo MP sea mayor.

Capítulo 3

Experimento I: Caso sin restringir

3.1 Introducción

En este capítulo se compara la capacidad predictiva de un modelo univariante lineal con un modelo periódico, de la forma de un VAR(p) ortogonalizado, donde las variables a estudiar son las diferentes estaciones de un serie temporal.

En una primera sección se presentan las series a analizar y se estudia el orden de integración de las variables. Una vez hecho esto, se pasan a estimar los modelos autorregresivos lineales identificados para cada una de las variables.

Posteriormente, se identifican y estiman los modelos periódicos para cada una de las series objeto de estudio. En este capítulo, los modelos VAR se estiman con las variables en niveles, lo que hace que no sea posible realizar contrastes de significatividad individual sobre los parámetros del modelo.

Para cada una de las variables se aplica el contraste de estacionalidad univariante desarrollado por Flores y Novales (1997). Se usa este contraste como herramienta para seleccionar el modelo correcto que genera cada una de las series. Se comprueba si el modelo seleccionado es aquel que mejores previsiones obtiene dentro de la muestra. También se estudia si aquel modelo que mejores previsiones intramuestrales obtiene, también es el que mejor prevé fuera de la muestra.

Se comprueba si el contraste consigue elegir el modelo que mejor prevé fuera

de la muestra. Además, se estudia si el modelo que mejor prevé la variable en conjunto, también es la que mejor prevé para cada uno de los días de la semana. Si esto no es así, se construye un modelo compuesto. Este modelo compuesto se elabora eligiendo el modelo que mejor prevé cada día dentro de la muestra, y se estudia si este comportamiento se traslada fuera de la muestra.

3.2 Datos y Análisis univariante

En esta sección se presenta un resumen de los datos utilizados y de los resultados más importantes del análisis univariante.

Se analizan series diarias de la cotización máxima del Ibex-35 para el período comprendido entre el 05/01/2004 hasta el 29/06/2007, y aquellos de sus componentes que no salieron del índice general en ese período. Esto hace un total de 910 observaciones para 25 series diferentes. Debido al tamaño de la muestra, ésta se adjunta en un CD junto con diferentes programas usados en la estimación de los diferentes modelos.

Para la construcción de los modelos se escoge la submuestra desde el 05/01/2004 hasta el 29/12/2006. Es decir se cuentan con 780 observaciones para realizar la identificación y estimación de los modelos univariantes.

Utilizando análisis gráficos se concluye que todas las series son integradas de orden 1, $I(1)$. Un resumen de las estimaciones de los modelos univariantes aparece en la tabla 3.1.

Tabla 3.1: Modelos univariantes sin intervenir

<i>Valor</i>	$\nabla \ln Valor$						
	ϕ_1	ϕ_2	ϕ_3	μ (%)	$\hat{\sigma}_a$ (%)	$Q(5)$	<i>Atípicos superiores a 3σ</i>
IBEX	0,14 (0,04)	–	–	0,06 (0,02)	0,6	4,6	02/04/04, 10/05/04, 19/05/04, 18/04/05, 19/10/05, 15/05/06, 18/05/06, 19/07/06, 27/09/06, 28/11/06

Continúa en la página siguiente

Tabla 3.1: Continuación

<i>Valor</i>	$\nabla \ln Valor$						
	ϕ_1	ϕ_2	ϕ_3	μ (%)	$\hat{\sigma}_a$ (%)	$Q(5)$	<i>Atípicos superiores a 3σ</i>
ABE	0,07 (0,03)	–	–	0,07 (0,03)	0,9	4,4	20/07/04, 03/09/04, 03/06/05, 29/06/05, 04/07/05, 01/09/05, 11/10/05, 17/10/05, 15/12/05, 24/04/06, 19/05/06, 03/07/06, 01/09/06, 08/11/06
ACS	0,12 (0,03)	–	–	0,13 (0,04)	1,0	2,1	02/03/04, 09/07/04, 22/02/06, 14/10/05, 19/10/05, 18/05/06, 08/06/06, 13/06/06, 04/10/06, 31/10/06
ACX	0,13 (0,03)	–	–	0,10 (0,04)	1,1	5,2	10/05/04, 16/11/04, 04/02/05, 08/03/05, 27/01/06, 24/10/06, 25/10/06
ALT	0,10 (0,03)	–0,09 (0,03)	–	0,07 (0,04)	1,0	3,6	12/02/04, 12/05/04, 15/12/04, 17/12/04, 20/12/04, 23/01/06, 26/01/06, 09/02/06, 13/03/06, 07/12/06
ANA	0,11 (0,03)	–	–	0,10 (0,04)	1,3	3,3	16/12/04, 19/10/05, 15/11/05, 30/11/05, 25/01/06, 09/02/06, 15/02/06, 21/03/06, 08/06/06, 15/06/06, 20/10/06, 01/12/06
BBVA	0,12 (0,03)	–	–	–	1,0	6,3	12/02/04, 13/05/04, 30/07/04, 07/10/04, 11/10/06, 12/10/06, 30/11/06
BKT	0,07 (0,03)	–	–	0,08 (0,04)	1,2	1,4	13/09/04, 01/03/05, 09/02/06, 20/02/06, 16/03/06, 20/04/06, 11/05/06, 12/05/06, 23/10/06
BTO	–	–	–	0,06 (0,03)	0,9	6,4	16/01/04, 15/03/04, 04/10/04, 28/01/05, 14/02/05, 20/02/06, 27/02/06, 12/06/06, 03/07/06, 20/09/06, 05/10/06, 06/10/06, 28/11/06
ELE	0,18 (0,03)	–	–	0,09 (0,04)	1,1	5,1	16/03/04, 06/09/05, 07/09/05, 21/02/06, 03/07/06, 27/07/06, 26/09/06, 27/09/06
ENG	0,13 (0,03)	–	–	0,08 (0,04)	1,1	1,9	10/12/04, 16/12/04, 16/02/05, 22/02/05, 19/10/05, 24/10/05, 18/05/06, 27/09/06, 08/12/06, 20/12/06, 21/12/06
FCC	0,08 (0,03)	–	–	0,12 (0,04)	1,1	5,1	16/12/04, 19/01/06, 03/03/06, 18/05/06, 08/06/06, 15/06/06, 21/07/06, 28/09/06, 22/12/06
FER	0,18 (0,03)	–	–	0,10 (0,04)	1,2	3,2	02/03/04, 09/07/04, 22/02/05, 14/10/05, 19/10/05, 18/05/06, 08/06/06, 13/06/06, 31/10/06
GAM	0,12 (0,03)	–	–	0,10 (0,05)	1,4	4,5	26/02/04, 27/02/04, 26/05/04, 04/08/04, 16/11/04, 02/09/05, 27/09/05, 21/02/06, 04/05/06, 04/10/06,
GAS	0,12 (0,03)	–0,10 (0,03)	–	–	1,0	1,3	28/10/04, 04/11/04, 21/02/05, 22/02/06, 23/02/06, 27/02/06, 28/02/06, 01/03/06, 26/05/06, 27/07/06, 28/07/06, 26/09/06, 27/09/06, 28/09/06

Continúa en la página siguiente

Tabla 3.1: Continuación

<i>Valor</i>	$\nabla \ln Valor$						
	ϕ_1	ϕ_2	ϕ_3	μ (%)	$\hat{\sigma}_a$ (%)	$Q(5)$	<i>Atípicos superiores a 3σ</i>
IBE	0,07 (0,03)	—	—	0,09 (0,03)	1,0	2,5	06/09/05, 21/02/06, 07/06/06
IBLA	0,06 (0,03)	−0,08 (0,03)	—	—	1,4	6,1	13/01/04, 12/03/04, 04/05/04, 29/07/05, 10/08/05, 15/12/05, 24/02/06, 15/05/06, 13/09/06, 04/10/06
IDR	0,12 (0,03)	−0,07 (0,03)	—	—	1,0	2,8	29/03/04, 19/05/04, 14/06/04, 29/06/05, 23/01/06, 03/04/06, 08/06/06, 15/06/06, 19/07/06, 25/07/06, 20/09/06, 28/11/06
ITX	—	—	—	0,12 (0,04)	1,2	2,0	11/02/04, 25/03/04, 14/06/05, 21/09/05, 14/06/06, 13/12/06
MVC	0,12 (0,03)	−0,13 (0,03)	0,11 (0,03)	0,06 (0,02)	1,9	20,9	02/01/06, 01/03/06, 20/03/06, 21/09/06, 25/09/06, 26/19/06, 28/09/06, 04/10/06, 13/10/06, 18/10/06 19/10/06, 25/10/06
POP	0,11 (0,03)	—	—	—	0,8	4,2	12/01/04, 22/07/04, 27/01/05, 31/01/05, 15/02/05, 21/03/06, 22/03/06, 24/03/06, 12/04/06, 15/05/06, 18/05/06, 29/06/06, 06/10/06, 25/10/06
REP	0,13 (0,03)	−0,07 (0,03)	—	—	1,1	3,9	22/09/05, 23/09/05, 06/10/05, 21/10/05, 29/11/05, 26/01/06, 18/05/06, 27/09/06, 11/10/06, 17/10/06
SAN	0,09 (0,03)	−0,07 (0,03)	—	—	0,9	2,3	29/04/04, 10/05/04, 19/05/04, 26/07/04, 27/07/04, 26/09/05, 26/10/05
TEF	—	—	—	—	0,9	1,7	12/01/04, 02/04/04, 10/05/04, 01/10/04, 21/06/05, 12/05/06, 26/05/06
UNF	—	—	—	0,12 (0,04)	1,1	1,0	17/02/04, 15/03/04, 21/03/05, 22/03/05, 05/09/05, 06/09/05, 07/09/05, 22/09/05, 23/09/05, 27/09/05, 24/11/05, 02/03/06, 18/15/06, 25/09/06

Fin de la tabla

3.3 Modelos Multivariantes

En este apartado, para cada uno de las 25 variables anteriores se construye el modelo periódico. Para ello se va a dividir cada serie diaria en cinco series, una para cada día de la semana: $(l_t, m_t, x_t, j_t \text{ y } v_t)$. Con estas cinco variables se va a identificar y estimar un VAR ortogonalizado en niveles

A cada serie se le realiza un profundo análisis de identificación, estimación y diagnóstico. Los resultados de este proceso aparecen en el apéndice 3.B. Para cada serie se presentan dos criterios de selección del orden del VAR: el criterio de Akaike y el criterio de Schwarz. En la gran mayoría de los casos los dos criterios coinciden. En aquellos casos donde no lo hacen, se elige el orden más pequeño y en la etapa de diagnóstico, si aparece estructura en el correlograma de los residuos, se decidirá incrementar el orden del mismo.

Todas las series analizadas se identifican como VAR(1). Cada uno de los modelos estimados aparecen en el apéndice 3.B, junto el gráfico de los residuos, y la tabla con los valores para los primeros 5 retardos de la función de correlación cruzada (CCF).

3.4 Contraste

En esta sección se presentan los resultados del contraste de estacionalidad desarrollado por Flores y Novales (1997). Para cada variable se decide el modelo que con mayor probabilidad haya generado los datos. Si no se rechaza la hipótesis nula, se selecciona el AR como modelo correcto. Si se rechaza la hipótesis nula, se elige el modelo periódico. Los resultados aparecen en la tabla 3.2.

La aplicación del contraste sugiere que en 22 de los 25 casos, el modelo periódico es la especificación correcta al 95 % de confianza. Es decir, en un 88 % de las series analizadas, se encuentra evidencia estadística para pensar que cada día de la semana tiene una dinámica diferente.

Las variables donde el contraste indica que el AR es el modelo elegido son: Acciona, Ferrovial e Iberdrola.

La principal conclusión del anterior resultado es que para 22 de las variables analizadas, se puede pensar en ajustar una especificación periódica, lo que implica que cada día de la semana responde diferente ante un shock igual, y este modelo no

es equivalente al modelo univariante estimado. Sólo en 3 de las variables es igual el modelo univariante lineal que su contraparte periódica, estadísticamente hablando.

En la siguiente sección se comprueba si el modelo seleccionado por el contraste es aquel que mejor prevé, tanto dentro como fuera de la muestra.

Tabla 3.2: Contraste de estacionalidad univariante

Valores	$\ln Lr$	$\ln Lsr$	Estadístico
IBEX	-51,23	-50,70	82,89
ABE	-46,97	-46,56	62,96
ACS	-46,33	-45,79	84,30
ACX	-45,27	-44,85	65,45
ALT	-46,27	-45,67	92,99
ANA	-43,56	-43,25	48,58*
BBVA	-46,99	-46,36	97,57
BKT	-46,04	-45,32	111,47
BTO	-48,02	-47,27	116,42
ELE	-45,85	-44,93	143,26
ENG	-46,19	-45,32	135,35
FCC	-45,41	-44,92	76,37
FER	-43,94	-43,74	31,00*
GAM	-42,90	-42,50	61,60
GAS	-47,04	-46,15	137,09
IBE	-46,79	-46,46	51,04*
IBLA	-43,22	-42,61	95,38
IDR	-45,97	-45,59	58,45
ITX	-45,64	-44,65	96,95
MVC	-41,25	-39,69	240,99
POP	-49,21	-48,74	73,00
REP	-45,43	-45,00	67,27
SAN	-47,36	-46,79	89,27
TEF	-47,92	-47,53	58,50
UNF	-45,48	-45,07	62,88

El valor crítico para una χ^2_{38} al 95 %, es 53,38.

3.5 Previsiones

En un primer momento se presenta la precisión de las previsiones dentro de la muestra, esto es, para el período comprendido entre el 05/01/2004 y el 29/12/2006. En la tabla 3.3 aparecen los RECM para cada uno de los valores, tanto para el total de la series, como para cada uno de los días. Los índices subrayados son aquellos para los que el contraste selecciona el modelo univariante. En negrita aparece señalado el RECM del modelo que mejor prevé para el global de la serie. Por último, se recuadran los RECM de los días donde el modelo que mejor prevé no es el que mejor lo hace para el global. Todos los valores aparecen multiplicados por diez mil.

Tabla 3.3: Precisión de las previsiones dentro de la muestra

	RECM			RECM			RECM	
	AR(p)	VAR(p)		AR(p)	VAR(p)		AR(p)	VAR(p)
IBEX	0,628	0,601	ABE	0,950	0,919	ACS	1,027	0,996
l	0,684	0,652	l	0,974	0,961	l	1,279	1,281
m	0,524	0,506	m	0,885	0,873	m	0,963	0,927
x	0,639	0,616	x	0,939	0,930	x	1,031	0,981
j	0,669	0,635	j	0,944	0,941	j	0,970	0,956
v	0,612	0,583	v	1,004	0,888	v	0,839	0,762
ACX	1,128	1,091	ALT	1,039	1,003	<u>ANA</u>	1,272	1,259
l	0,972	0,938	l	1,012	0,983	l	1,096	1,098
m	1,079	1,022	m	0,894	0,849	m	1,250	1,239
x	1,198	1,153	x	1,008	0,950	x	1,317	1,311
j	1,062	1,050	j	1,302	1,293	j	1,389	1,360
v	1,299	1,264	v	0,930	0,878	v	1,288	1,269
BBVA	1,093	0,927	BKT	1,217	1,069	BTO	0,933	0,804
l	1,461	1,168	l	1,103	1,001	l	1,210	0,868
m	0,771	0,785	m	0,936	0,863	m	0,837	0,718
x	0,958	0,841	x	1,261	1,105	x	0,752	0,745
j	0,915	0,934	j	1,617	1,326	j	0,816	0,704
v	1,220	0,859	v	1,052	0,994	v	0,978	0,954
ELE	1,122	1,086	ENG	1,045	1,000	FCC	1,126	1,091
l	1,048	1,019	l	1,003	0,968	l	1,143	1,119
m	1,621	1,568	m	0,904	0,864	m	1,016	0,968
x	0,983	0,941	x	1,028	1,009	x	1,046	1,016
j	0,916	0,887	j	1,251	1,187	j	1,293	1,244
v	0,875	0,855	v	1,007	0,940	v	1,110	1,086

Continúa en la página siguiente

Tabla 3.3: Continuación

	RECM			RECM			RECM	
	AR(p)	VAR(p)		AR(p)	VAR(p)		AR(p)	VAR(p)
FER	1,228	1,270	GAM	1,426	1,382	GAS	0,991	0,941
l	1,274	1,264	l	1,199	1,190	l	0,830	0,821
m	1,080	1,308	m	1,416	1,394	m	0,880	0,862
x	1,025	1,155	x	1,517	1,440	x	1,239	1,183
j	1,328	1,346	j	1,656	1,593	j	1,075	0,984
v	1,392	1,268	v	1,297	1,257	v	0,869	0,802
IBE	0,960	0,969	IBLA	1,380	1,347	IDR	1,047	1,033
l	0,880	0,800	l	1,200	1,077	l	1,109	1,106
m	1,024	0,931	m	1,161	1,259	m	0,945	0,938
x	1,007	1,322	x	1,742	1,694	x	1,115	1,073
j	0,778	0,814	j	1,233	1,223	j	1,114	1,123
v	1,080	0,882	v	1,477	1,402	v	0,934	0,908
ITX	1,167	1,082	MVC	1,889	1,759	POP	0,764	0,727
l	1,066	0,948	l	1,763	1,604	l	0,797	0,688
m	0,989	0,872	m	1,509	1,361	m	0,745	0,706
x	1,320	1,247	x	2,257	2,176	x	0,815	0,780
j	1,390	1,358	j	2,365	2,149	j	0,807	0,777
v	1,012	0,894	v	1,333	1,300	v	0,643	0,679
REP	1,111	1,072	SAN	0,929	0,887	TEF	0,922	0,829
l	1,030	1,108	l	1,131	1,068	l	0,978	0,815
m	1,215	1,122	m	0,778	0,741	m	0,810	0,759
x	0,953	0,908	x	0,885	0,863	x	0,843	0,827
j	1,288	1,211	j	0,930	0,894	j	0,850	0,826
v	1,035	0,987	v	0,884	0,840	v	1,096	0,911
UNF	1,106	1,066						
l	1,271	1,268						
m	1,144	1,059						
x	0,865	0,849						
j	1,159	1,100						
v	1,050	1,009						

Fin de la tabla

Si se fija la atención en los 3 valores para los que el contraste no se ha rechazado, en dos de ellos, Ferrovial e Iberdrola, la previsión dentro de la muestra del modelo autorregresivo es mejor que la del modelo periódico. En cambio Acciona, la mejor previsión dentro de la muestra la consigue el modelo periódico.

Sin embargo, para los 22 valores para los que se ha rechazado el contraste, la

mejor previsión dentro de la muestra la consigue el modelo multivariante.

Otra característica que destaca es que para varias series, el modelo que mejor prevé para el global de la serie, no es el modelo que mejor prevé para cada uno de los días. Por señalar un ejemplo, el modelo periódico prevé mejor el valor BBVA, pero es el modelo univariante el que mejor resultado en previsión tiene para el martes y el jueves.

Se comprueba si estas características intramuestrales se dan fuera de la muestra. Si esto es así, el modelo periódico será el que mejor lo haría en 23 de los 25 casos considerados, es decir, el 92 % de las veces. Aunque existe la posibilidad de que el modelo univariante fuera superior para algún día concreto.

En la tabla 3.4 se presenta el resultado global para cada serie, y también la precisión de cada modelo para prever dentro de la semana, para el período comprendido entre 01/01/2007 hasta el 29/06/2007. Al igual que en la anterior tabla todos los valores están multiplicados por diez mil.

Tabla 3.4: Precisión de las previsiones fuera de la muestra

	RECM			RECM			RECM	
	AR(p)	VAR(p)		AR(p)	VAR(p)		AR(p)	VAR(p)
IBEX	0,827	0,850	ABE	0,919	0,984	ACS	1,113	1,137
l	0,731	0,731	l	0,960	1,009	l	0,927	0,923
m	0,667	0,586	m	0,652	0,619	m	0,806	0,802
x	1,067	1,126	x	0,900	0,998	x	1,511	1,575
j	0,823	0,854	j	0,989	1,074	j	1,166	1,160
v	0,790	0,859	v	1,045	1,134	v	1,020	1,067
ACX	1,592	1,691	ALT	1,812	1,843	<u>ANA</u>	2,033	2,075
l	1,436	1,436	l	1,001	0,907	l	2,000	1,978
m	0,845	0,909	m	0,728	0,972	m	1,884	1,917
x	1,778	2,206	x	0,644	0,707	x	2,371	2,431
j	1,897	1,896	j	3,536	3,565	j	2,034	2,131
v	1,772	1,716	v	1,402	1,416	v	1,835	1,870

Continúa en la página siguiente

Tabla 3.4: Continuación

	RECM			RECM			RECM	
	AR(p)	VAR(p)		AR(p)	VAR(p)		AR(p)	VAR(p)
BBVA	1,173	1,180	BKT	1,371	1,421	BTO	1,078	1,097
l	0,960	0,990	l	1,114	1,117	l	1,410	1,261
m	1,004	1,055	m	1,241	1,265	m	0,940	0,863
x	1,293	1,362	x	1,815	1,919	x	1,265	1,209
j	0,903	1,224	j	1,325	1,491	j	0,812	0,873
v	1,570	1,187	v	1,251	1,157	v	0,820	1,206
ELE	0,694	0,705	ENG	1,196	1,249	FCC	1,401	1,385
l	0,698	0,647	l	1,208	1,302	l	1,105	1,102
m	0,733	0,692	m	0,769	0,861	m	0,853	0,865
x	0,678	0,726	x	1,541	1,495	x	2,055	2,063
j	0,695	0,747	j	1,158	1,292	j	1,347	1,196
v	0,662	0,710	v	1,177	1,211	v	1,351	1,391
<u>FER</u>	1,321	1,402	GAM	1,774	1,910	GAS	1,397	1,438
l	1,420	1,397	l	1,739	1,722	l	1,024	1,092
m	1,075	1,209	m	1,336	1,627	m	1,786	1,689
x	1,493	1,670	x	2,001	2,333	x	1,457	1,592
j	1,236	1,243	j	1,941	1,917	j	1,373	1,405
v	1,341	1,440	v	1,779	1,874	v	1,229	1,337
<u>IBE</u>	1,373	1,432	IBLA	1,650	1,839	IDR	1,036	1,069
l	1,020	1,157	l	1,242	1,727	l	0,821	0,815
m	1,161	1,218	m	2,111	2,052	m	1,248	1,274
x	1,698	1,894	x	1,878	2,234	x	0,863	1,006
j	1,349	1,374	j	1,246	1,608	j	1,065	1,061
v	1,529	1,399	v	1,592	1,463	v	1,123	1,136
ITX	1,158	1,218	MVC	1,657	1,732	POP	1,121	1,125
l	1,213	1,198	l	1,553	1,705	l	1,048	1,118
m	1,128	1,086	m	2,489	2,455	m	0,978	0,973
x	1,215	1,380	x	1,238	1,008	x	1,579	1,618
j	1,097	1,328	j	1,156	1,466	j	1,053	0,918
v	1,132	1,065	v	1,501	1,704	v	0,794	0,823
REP	1,453	1,226	SAN	1,018	1,106	TEF	0,931	0,931
l	0,861	0,895	l	0,901	1,125	l	0,820	0,825
m	1,050	0,801	m	0,864	0,838	m	0,698	0,647
x	1,471	1,259	x	1,228	1,328	x	1,210	1,184
j	1,473	1,187	j	0,867	0,863	j	0,884	0,875
v	2,093	1,755	v	1,167	1,280	v	0,938	1,034

Continúa en la página siguiente

Tabla 3.4: Continuación

	RECM			RECM			RECM	
	AR(p)	VAR(p)		AR(p)	VAR(p)		AR(p)	VAR(p)
UNF	1,378	1,386						
l	0,918	0,975						
m	1,607	1,642						
x	1,563	1,537						
j	1,393	1,437						
v	1,298	1,238						

Fin de la tabla

A la vista de los resultados, estos no pueden ser más desalentadores. En 23 de los 25 casos, el modelo univariante es el modelo con mejor previsión fuera de la muestra. Sólo para FCC y Repsol el modelo periódico tiene mejor precisión a la hora de prever.

Llama la atención los casos de BBVA, Banco Popular, Telefónica y Unión Fenosa, donde los dos modelos tienen unos resultados muy similares, aunque en todos ellos el modelo univariante es superior al periódico.

La calidad predictiva extramuestral del modelo periódico es bastante inferior a la del modelo univariante, en el 92 % de los casos prevé mejor este último. Queda claro que la fortaleza predictiva del modelo periódico dentro de la muestra no se traduce en mejoras de previsión fuera de la muestra.

Al igual que pasa con las previsiones dentro de la muestra, el modelo que mejor lo hace para el global de la serie fuera de la muestra no tiene porque ser el que mejores resultados obtiene para todos los días de la semana. Se comprueba si estos días coinciden y se puede usar esta información para mejorar la previsión.

Volviendo a la tabla 3.3, en 17 de los 25 casos el modelo que mejor prevé el global de la serie, es también el que mejor prevé para cada uno de los días. Para las 8 variables restantes, Acciona, BBVA, Ferrovial, Iberdrola, Iberia, Indra, Banco Popular y Repsol, no todos los días un modelo es el mejor para calcular las previsiones.

Es por esto que se plantea prever cada día fuera de la muestra con el modelo que mejores previsión haya obtenido dentro de la muestra para ese día. Los resultados de este experimento aparecen en la tabla 3.5.

Tabla 3.5: Precisión de las previsiones modelos compuestos

	RECM		
	AR(p)	VAR(p)	Compuesto
<u>ANA</u>	2,033	2,075	2,080
BBVA	1,173	1,180	1,102
<u>FER</u>	1,321	1,402	1,338
<u>IBE</u>	1,373	1,432	1,377
IBLA	1,650	1,839	1,852
IDR	1,036	1,069	1,069
POP	1,121	1,125	1,121
REP	1,453	1,226	1,221

Los resultados no tan buenos como se esperaba ya que en muy pocos casos, usando la información intramuestral, se consiguen mejoras en las previsiones extramuestrales.

Sólo hay dos valores donde el modelo compuesto es el que mejores previsiones obtiene. Estas series son BBVA y Repsol. Para el resto de las series, el modelo compuesto no consigue batir al modelo univariante, que es el modelo que mejores previsiones fuera de la muestra había conseguido, para todos los casos considerados.

Se considera interesante realizar un contraste de igualdad de precisión en las previsiones de los modelos. Se decide optar por el contraste de Diebold y Mariano (1995) debido a su relevancia en la literatura. Se lleva a cabo de la siguiente manera: al ser un contraste de comparación entre dos modelos, se comprueba primero si estadísticamente son iguales las previsiones fuera de la muestra del modelo univariante y del modelo periódico. Si son iguales, se elige aquel con menor RECM para comprobar si sus previsiones son iguales a las del modelo compuesto. Si se tiene que las previsiones del modelo univariante y del modelo periódico son diferentes, entonces se compara el modelo compuesto con el modelo que se haya seleccionado

con el contraste de estacionalidad univariante.

Los resultados se presentan en la tabla 3.6:

Tabla 3.6: Contraste de Diebold-Mariano

ANA	VAR(p)	Compuesto	BBVA	VAR(p)	Compuesto
AR(p)	1,601 (1,007)	1,676 (1,031)	AR(p)	0,200* (1,007)	1,103 (1,064)
FER	VAR(p)	Compuesto	IBE	VAR(p)	Compuesto
AR(p)	1,858 (1,007)	0,417* (1,064)	AR(p)	1,150 (1,007)	0,194* (1,086)
IBLA	VAR(p)	Compuesto	IDR	VAR(p)	Compuesto
AR(p)	1,847 (1,007)		AR(p)	1,318 (1,007)	
VAR(p)		0,484* (1,031)	VAR(p)		0,101* (1,031)
POP	VAR(p)	Compuesto	REP	VAR(p)	Compuesto
AR(p)	0,303* (1,007)	0,361* (1,031)	AR(p)	2,467 (1,007)	
VAR(p)			VAR(p)		0,525* (1,031)

Como valores críticos se toman los obtenidos por McCracken (2007). En la tabla 3.6, debajo del valor del estadístico, aparece el valor crítico de McCracken al 95 % de confianza. Los valores para los que el contraste indica que las dos previsiones son iguales, se señalan con un asterisco.

Los resultados indican que todas las previsiones de los modelos compuestos, salvo las de Acciona y BBVA, son estadísticamente iguales a las del modelo periódico o a las del modelo univariante. Sin embargo, estos resultados pueden estar afectados por la falta de potencia del contraste de Diebold y Mariano.

3.6 Conclusiones

En este capítulo se ha estimado, para 25 valores bursátiles, un modelo univariante y un modelo periódico, en forma de VAR ortogonalizado, cuyas variables son los cinco días de la semana laborable.

Todos los modelos univariantes han resultado ser autorregresivos de orden 1,

2 ó 3, menos en el caso de Banesto, Inditex, Telefónica y Unión Fenosa, donde las variables siguen un paseo aleatorio.

Por su parte se han identificado y estimado modelos VAR(1) para todas las variables.

Al aplicar el contraste de estacionalidad univariante desarrollado por Flores y Novales (1997) en 22 de los 25 casos se ha rechazado la hipótesis nula al 95 % de nivel de confianza. Este resultado indica que en un 80 % de las series analizadas, se encuentra evidencia estadística para pensar que cada día de la semana puede tener un dinámica diferente. Los valores donde el contraste indica que el modelo univariante es la especificación correcta son: Acciona, Ferrovial e Iberdrola.

Al calcular las previsiones dentro de la muestra, el contraste demuestra que consigue identificar de manera correcta el modelo que mejores previsiones intramuestrales tiene. En 24 de los 25 casos el contraste elige el modelo que mejor prevé dentro de la muestra.

Sin embargo, estos resultado no se trasladan fuera de la muestra. Si es cierto, que cuando el contraste selecciona el modelo univariante, éste es el que mejores previsiones fuera de la muestra obtiene. Sin embargo, en los 23 casos que selecciona el modelo periódico, sólo en 2 de ellos, es el modelo periódico el que mejor prevé. Estos dos valores son FCC y Repsol.

Además se encuentra otro resultado adicional, para 8 series el modelo que mejor prevé el global de la serie, no es el modelo que mejor predice para cada uno de los días.

Al construir un modelo compuesto para estas 8 variables, sólo en 2 de ellos, Repsol y BBVA, éste consigue mejorar la previsión de los anteriores modelos. Para los 6 casos restantes parece que las características dentro de la muestra no se trasladan fuera de ella.

Resumiendo, en este primer experimento, el contraste no ha demostrado que sea capaz de seleccionar aquel modelo con el que se puede prever mejor. Además,

aunque existen 8 series donde un único modelo no es el mejor para prever todos los días, cuando se componen los dos modelos usando la información intramuestral, no existe ninguna mejora salvo en un par de casos.

Se cree que estos resultados se deben a la sobreparametrización del modelo periódico. Esto está haciendo que se rechace el contraste de estacionalidad univariante más veces de las que es adecuado. Por ello, en el próximo capítulo, se repite el experimento pero ajustando modelos periódicos de corrección del error. Estos modelos se construyen con series estacionarias y por tanto se puede realizar contraste de significatividad individual para cada parámetro. De esta manera se eliminarán del modelo aquellos que sean estadísticamente iguales a 0.

3.A Apéndice: Descripción gráfica de las series

En los gráficos siguientes se presentan la diferencia regular del logaritmo de cada una de las series objeto de estudio.




Gráfico 3.1: Rendimientos de los valores

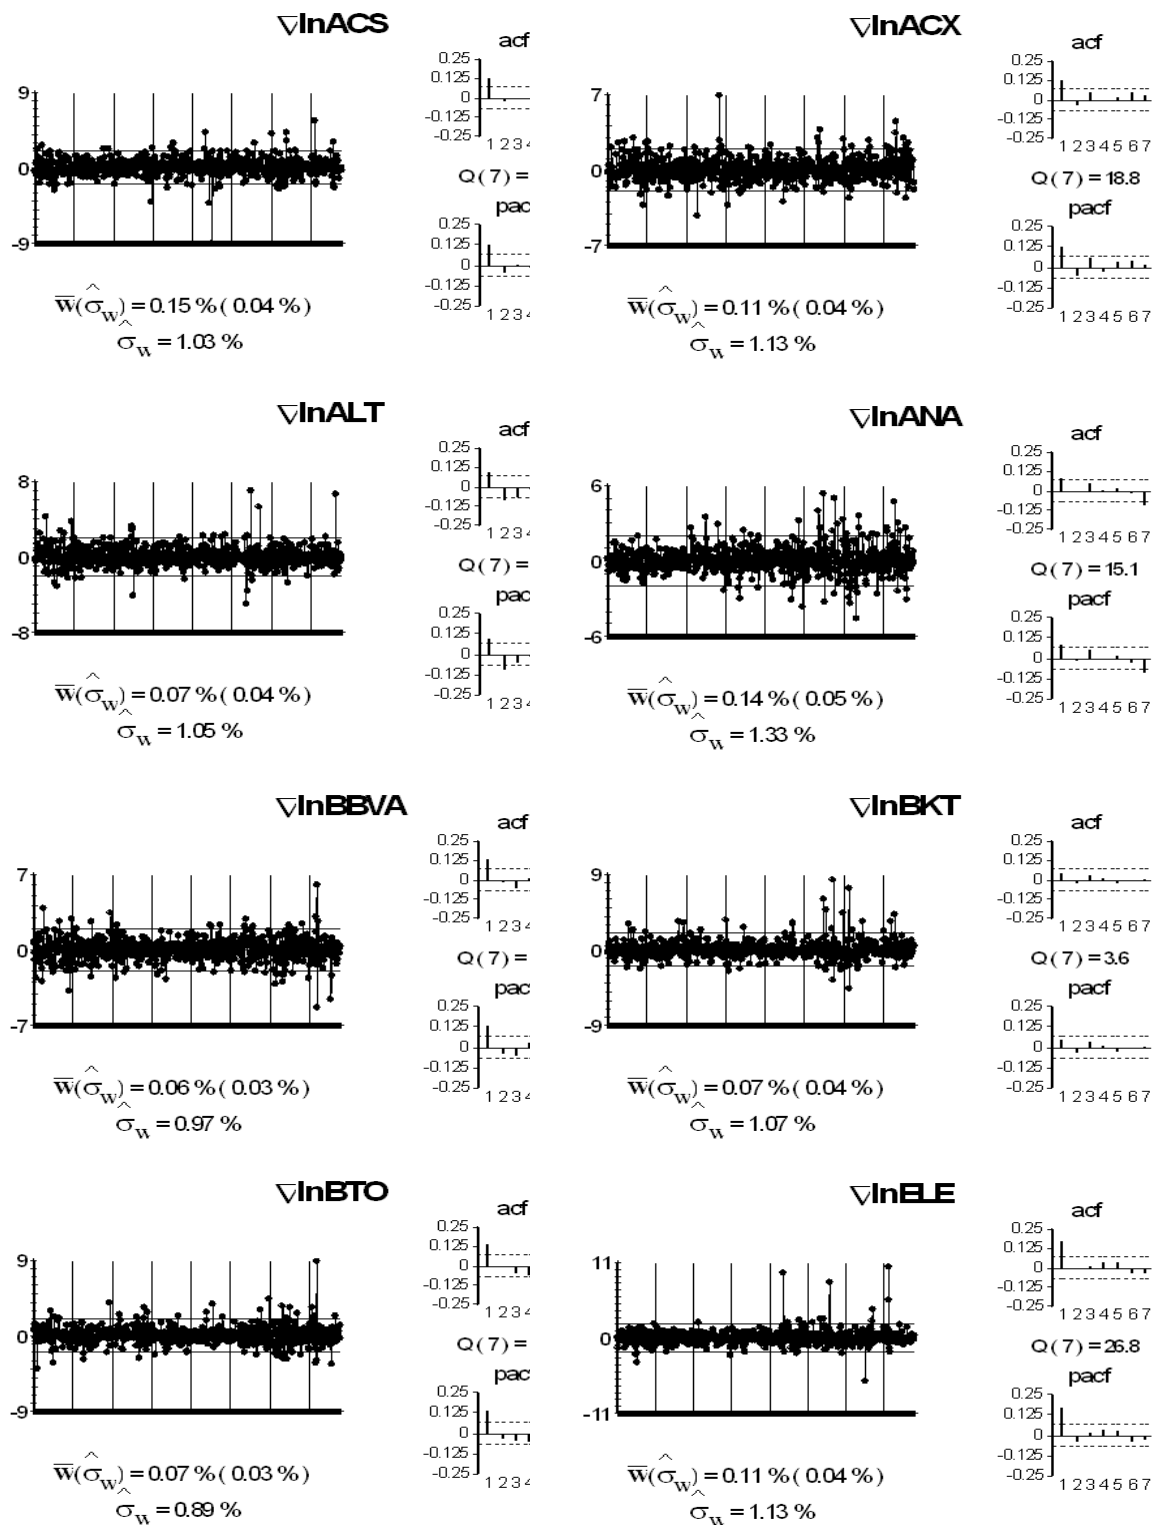


Gráfico 3.2: Cont: Rendimientos de los valores

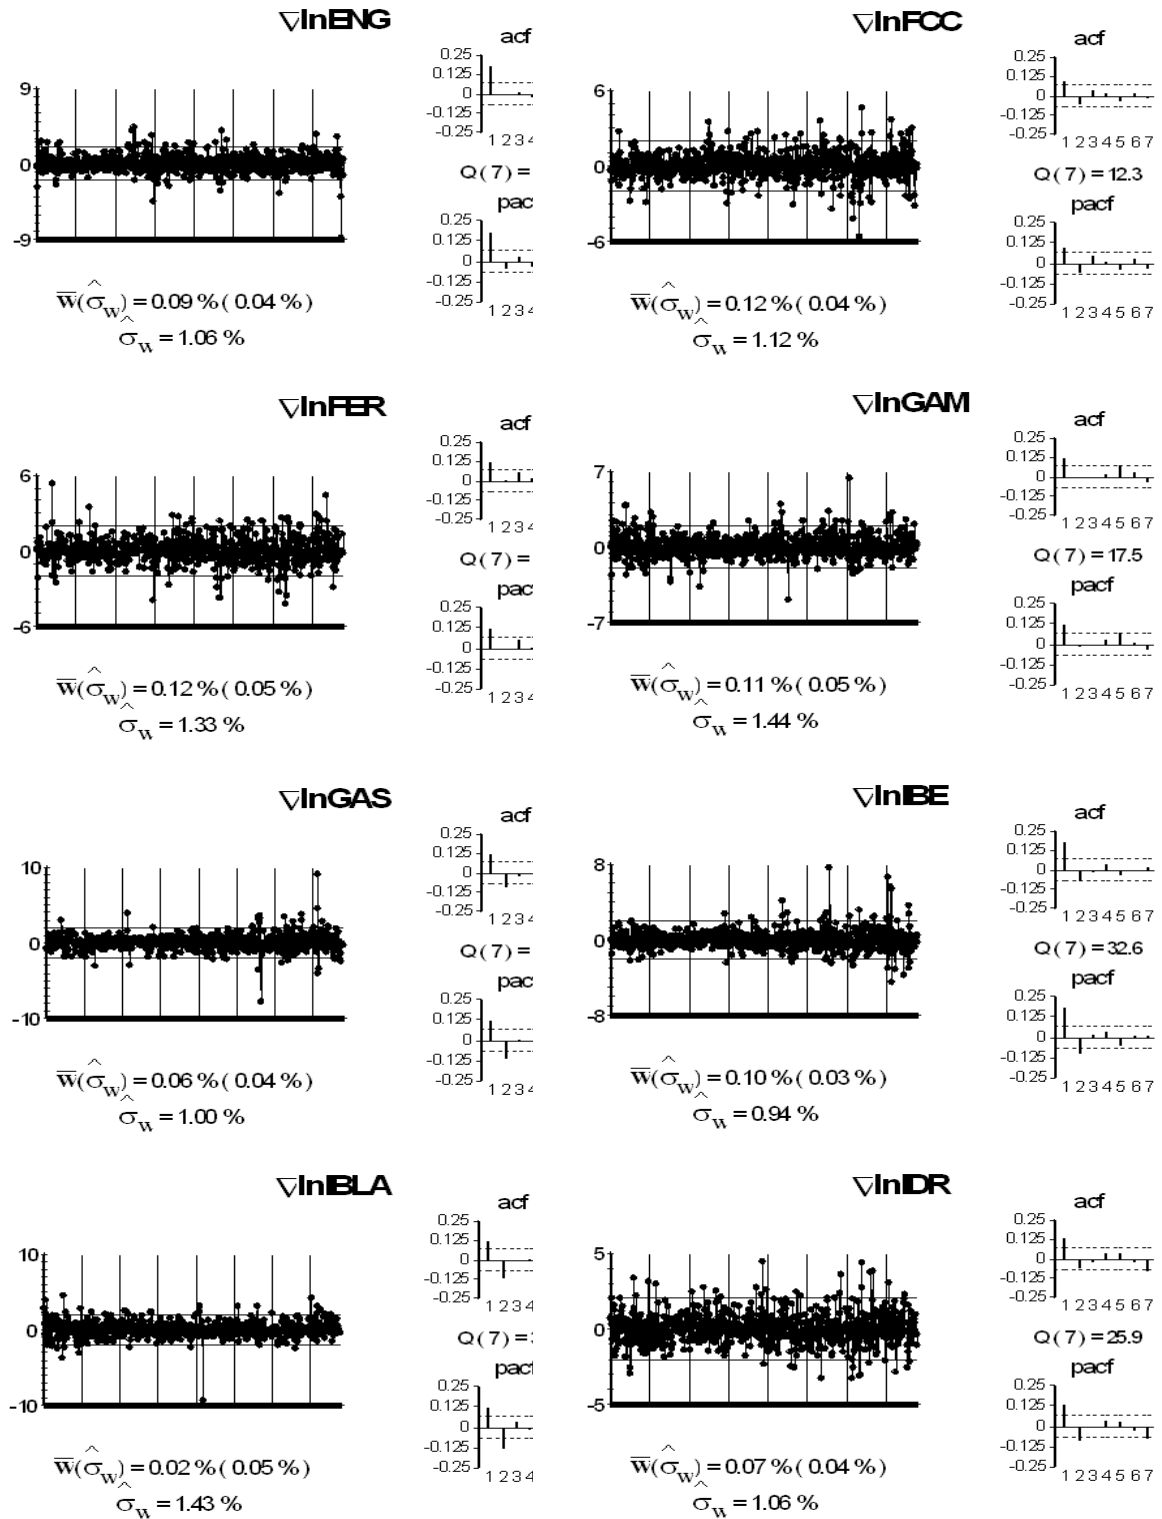


Gráfico 3.3: Cont: Rendimientos de los valores

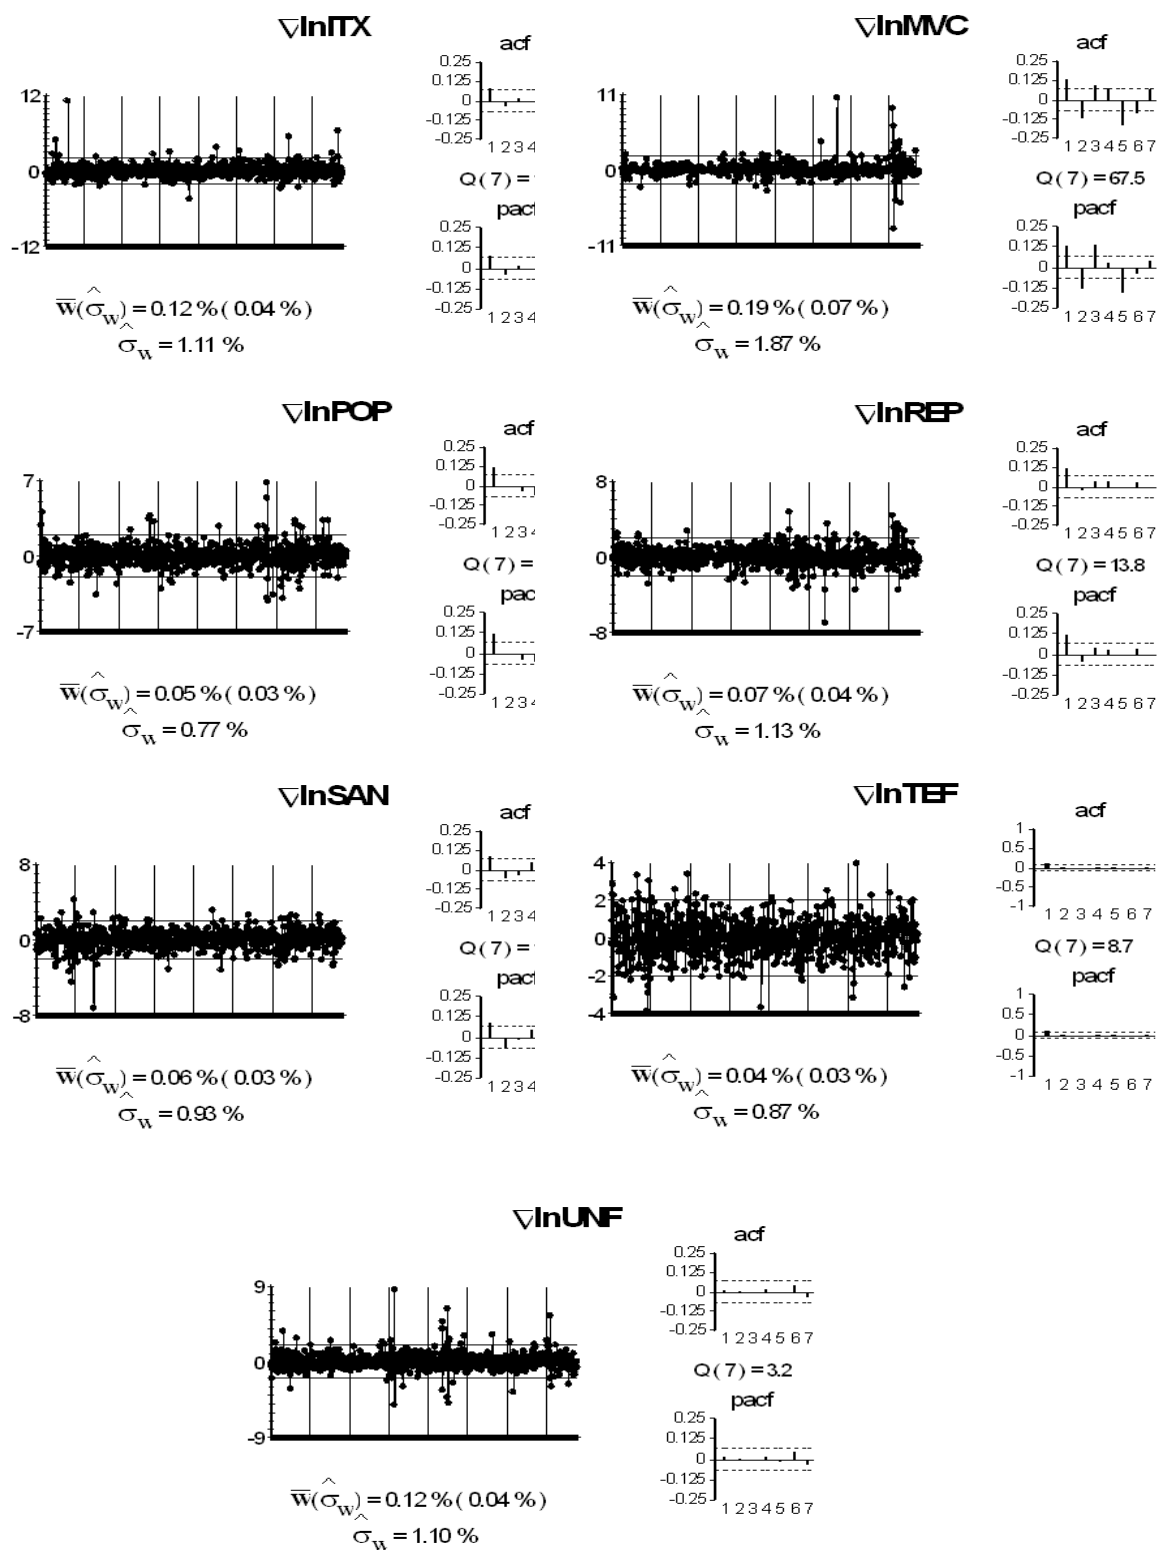


Gráfico 3.4: Cont: Rendimientos de los valores

3.B Apéndice: Estimación modelos VAR

3.B.1 IBEX-35

3.B.1.1 Elección orden del VAR

En la tabla 3.7 se muestran los estadísticos de Akaike y de Schwarz para diversos ordenes del VAR.

Tabla 3.7: IBEX-35: Elección del orden del VAR

Retardos	1	2	3	4
AIC	-50,83	-50,76	-50,66	-50,46
SC	-50,26	-49,67	-49,08	-48,37

Los dos criterios no difieren y por ello se estima un VAR(1) con constante.

3.B.1.2 Estimación modelo VAR

Se estiman todos los parámetros de forma conjunta por mínimos cuadrados generalizados. Los resultados aparecen en la tabla 3.8.

Tabla 3.8: IBEX-35: Estimación del VAR(1) ortogonalizado

Variable dependiente	Ecuaciones ^a				
	l_t	m_t	x_t	j_t	v_t
μ	-0,0058 (0,028)	0,012 (0,022)	-0,015 (0,027)	-0,018 (0,028)	0,012 (0,026)
l_t		1,07 (0,06)	-0,21 (0,13)	0,036 (0,138)	0,040 (0,127)
m_t			1,09 (0,10)	0,017 (0,139)	-0,031 (0,138)
x_t				1,04 (0,08)	-0,29 (0,11)
j_t					1,27 (0,08)
l_{t-1}	-0,24 (0,10)	0,070 (0,083)	-0,033 (0,100)	0,035 (0,104)	0,11 (0,09)
m_{t-1}	0,32 (0,14)	-0,10 (0,11)	-0,091 (0,133)	-0,19 (0,14)	-0,18 (0,13)
x_{t-1}	-0,077 (0,124)	-0,053 (0,097)	0,18 (0,12)	0,14 (0,12)	0,096 (0,114)
j_{t-1}	-0,33 (0,14)	0,067 (0,114)	0,028 (0,138)	-0,019 (0,143)	-0,19 (0,13)
v_{t-1}	1,32 (0,09)	-0,057 (0,110)	0,034 (0,133)	-0,064 (0,138)	0,18 (0,13)

^aLa tabla muestra los coeficientes estimados del modelo VAR donde cada columna representa una ecuación del mismo. Entre paréntesis se presentan las desviaciones típicas.

La matriz de covarianzas se presenta en (3.1).

$$\Sigma_u = \begin{pmatrix} 4,41E-05 & 4,73E-05 & 4,26E-05 & 4,69E-05 & 4,75E-05 \\ 4,73E-05 & 7,78E-05 & 7,52E-05 & 8,16E-05 & 8,14E-05 \\ 4,26E-05 & 7,52E-05 & 1,13E-04 & 1,21E-04 & 1,20E-04 \\ 4,69E-05 & 8,16E-05 & 1,21E-04 & 1,71E-04 & 1,82E-04 \\ 4,75E-05 & 8,14E-05 & 1,20E-04 & 1,82E-04 & 2,30E-04 \end{pmatrix} \quad (3.1)$$

El gráfico 3.5 muestra los residuos del VAR(1). Por otro lado, en la tabla 3.9 se presentan las funciones de correlación cruzadas. En ninguna de ellas se aprecian correlaciones significativas, por lo cual, estos resultados sugieren que el modelo de la tabla 3.8 representa de forma adecuada la correlación dinámica entre las variables.

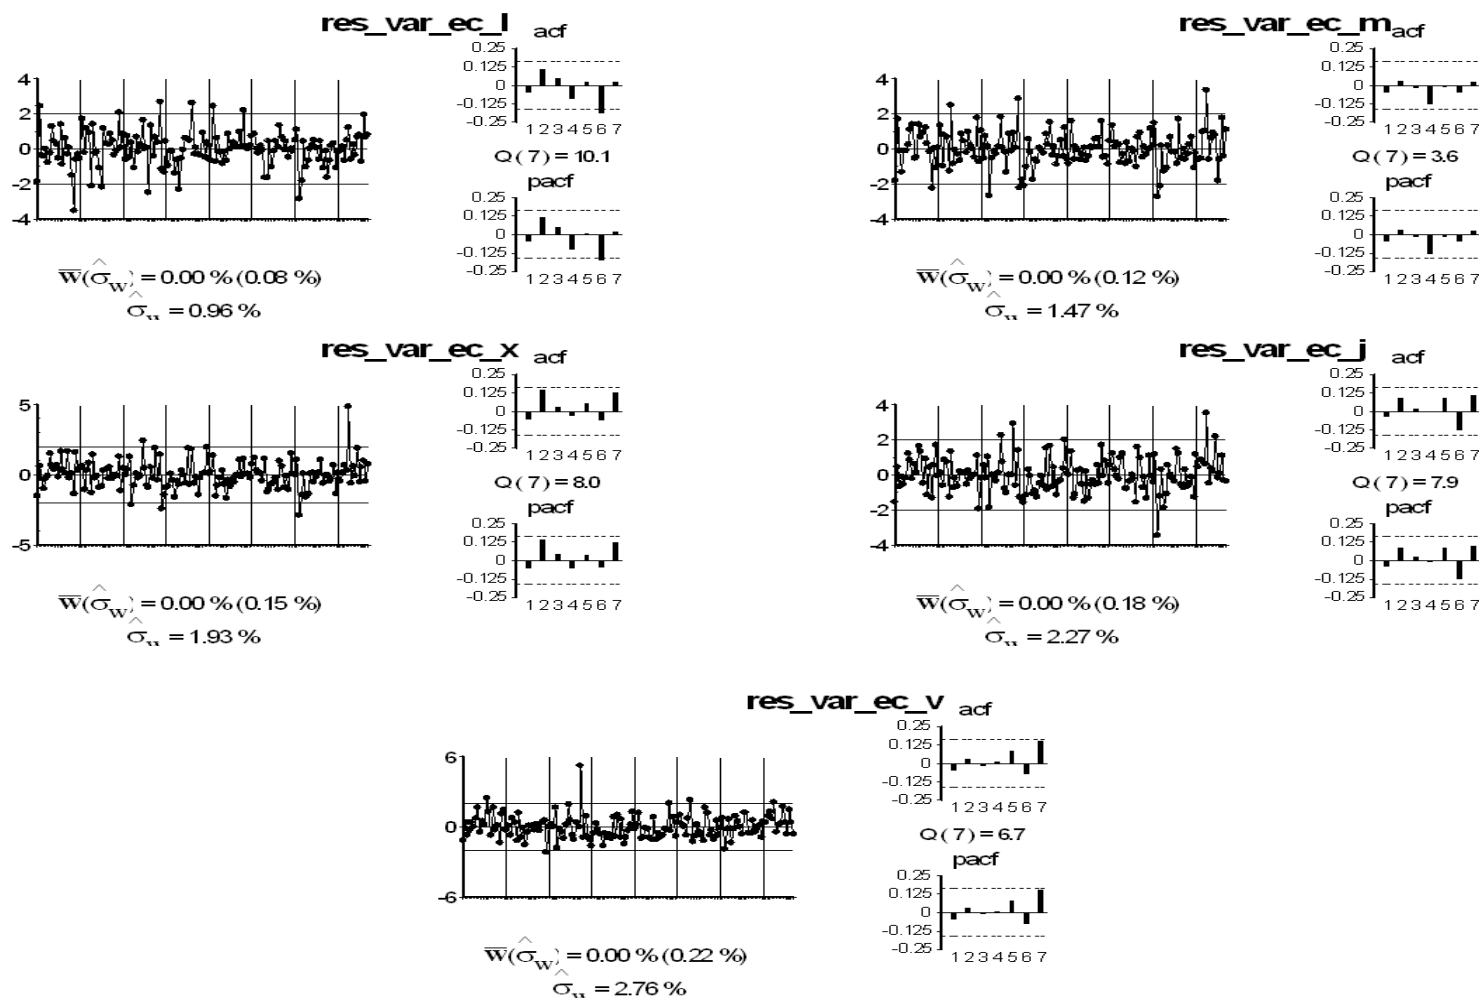


Gráfico 3.5: IBEX-35: Residuos del VAR(1)

Tabla 3.9: IBEX-35: Función de correlación cruzada residual del VAR(1)

Retardos	r_{11}	r_{12}	r_{13}	r_{14}	r_{15}
1	-0,045	-0,031	-0,025	-0,027	-0,034
2	0,116	0,021	0,101	0,111	0,083
3	0,044	-0,030	0,011	0,035	-0,024
4	-0,090	-0,143	-0,122	-0,114	-0,139
5	0,027	0,004	0,014	0,027	-0,001
	r_{21}	r_{22}	r_{23}	r_{24}	r_{25}
1	-0,081	-0,044	-0,037	-0,032	-0,037
2	0,059	0,033	0,164*	0,160	0,148
3	0,034	-0,018	0,037	0,043	-0,036
4	-0,092	-0,126	-0,118	-0,050	-0,066
5	0,034	-0,011	-0,033	0,030	0,016
	r_{31}	r_{32}	r_{33}	r_{34}	r_{35}
1	-0,100	-0,072	-0,058	-0,053	-0,049
2	0,024	0,063	0,145	0,140	0,095
3	0,027	0,012	0,031	0,013	-0,060
4	-0,050	-0,034	-0,036	0,002	-0,006
5	0,119	0,038	0,052	0,109	0,083
	r_{41}	r_{42}	r_{43}	r_{44}	r_{45}
1	-0,074	-0,056	-0,044	-0,040	-0,036
2	0,029	0,038	0,115	0,092	0,051
3	0,036	0,015	0,053	0,021	-0,040
4	-0,075	-0,026	-0,038	-0,003	-0,007
5	0,090	0,058	0,066	0,094	0,092
	r_{51}	r_{52}	r_{53}	r_{54}	r_{55}
1	-0,092	-0,071	-0,054	-0,050	-0,045
2	0,041	0,030	0,098	0,075	0,035
3	-0,043	-0,002	0,033	0,005	-0,017
4	-0,044	-0,015	-0,021	0,023	0,012
5	0,075	0,094	0,093	0,089	0,082

DT= $\frac{2}{\sqrt{T}} = 0,161$. En * significativos al 95 %.

3.B.2 Abertis

3.B.2.1 Elección orden del VAR

En la tabla 3.10 aparecen los estadísticos de Akaike y de Schwarz para diversos ordenes del VAR.

Tabla 3.10: Abertis: Elección del orden del VAR

Retardos	1	2	3	4
AIC	-32,39	-32,22	-31,98	-31,89
SC	-31,80	-31,14	-30,39	-29,80

Al no diferir los dos criterios se estima un VAR(1) con constante.

3.B.2.2 Estimación modelo VAR

Los parámetros se estiman de forma conjunta por mínimos cuadrados generalizados. Los resultados aparecen en la tabla 3.11.

Tabla 3.11: Abertis: Estimación del VAR(1) ortogonalizado

Variable dependiente	Ecuaciones ^a				
	l_t	m_t	x_t	j_t	v_t
μ	0,0032 (0,012)	0,013 (0,011)	0,019 (0,012)	0,014 (0,012)	-0,0038 (0,0114)
l_t		1,08 (0,07)	-0,058 (0,124)	-0,11 (0,12)	-0,17 (0,12)
m_t			1,07 (0,09)	0,095 (0,126)	-0,013 (0,120)
x_t				1,03 (0,08)	-0,030 (0,113)
j_t					1,18 (0,08)
l_{t-1}	0,077 (0,090)	0,10 (0,08)	0,075 (0,088)	-0,13 (0,09)	-0,012 (0,008)
m_{t-1}	0,10 (0,13)	-0,15 (0,12)	-0,057 (0,125)	-0,067 (0,127)	0,027 (0,120)
x_{t-1}	-0,18 (0,12)	-0,062 (0,108)	-0,032 (0,11)	0,22 (0,12)	0,079 (0,112)
j_{t-1}	-0,13 (0,13)	0,11 (0,12)	0,071 (0,128)	-0,0070 (0,1308)	-0,24 (0,12)
v_{t-1}	1,11 (0,09)	-0,078 (0,115)	-0,073 (0,123)	-0,036 (0,125)	0,18 (0,12)

^aLa tabla muestra los coeficientes estimados del modelo VAR donde cada columna representa una ecuación del mismo. Entre paréntesis se presentan las desviaciones típicas.

La matriz de covarianzas se presenta en (3.2).

$$\Sigma_u = \begin{pmatrix} 9,51E-05 & 1,02E-04 & 1,04E-04 & 1,06E-04 & 1,05E-04 \\ 1,02E-04 & 1,88E-04 & 1,95E-04 & 2,07E-04 & 2,19E-04 \\ 1,04E-04 & 1,95E-04 & 2,91E-04 & 3,06E-04 & 3,32E-04 \\ 1,06E-04 & 2,07E-04 & 3,06E-04 & 4,14E-04 & 4,57E-04 \\ 1,05E-04 & 2,19E-04 & 3,32E-04 & 4,57E-04 & 5,89E-04 \end{pmatrix} \quad (3.2)$$

Los residuos del VAR(1) aparecen en el gráfico 3.6. Por otro lado, en la tabla 3.12 se presentan las funciones de correlación cruzadas. Siete de las correlaciones son significativas, además algunas son significativas en el primer y segundo retardo. Puede plantearse la necesidad de incrementar el orden del VAR, pero en este primer experimento sin restringir, se decide estimar el VAR(1), por lo que se considera que modelo de la tabla 3.11 es adecuado.

Tabla 3.12: Abertis: Función de correlación cruzada residual del VAR(1)

Retardos	r_{11}	r_{12}	r_{13}	r_{14}	r_{15}
1	-0,205*	0,007	-0,004	0,016	-0,009
2	-0,057	-0,047	-0,019	0,033	0,037
3	0,091	0,016	-0,024	0,102	-0,093
4	0,008	-0,093	0,015	-0,044	0,033
5	-0,001	-0,023	0,047	-0,043	-0,045
	r_{21}	r_{22}	r_{23}	r_{24}	r_{25}
1	-0,147	-0,003	-0,003	0,012	0,001
2	-0,019	-0,040	0,013	0,063	-0,002
3	0,146	0,124	0,051	-0,063	-0,005
4	-0,108	0,103	0,215*	-0,040	0,022
5	0,046	0,059	0,073	-0,012	0,015
	r_{31}	r_{32}	r_{33}	r_{34}	r_{35}
1	-0,077	-0,002	0,006	0,006	-0,004
2	0,036	0,011	0,005	0,070	0,052
3	-0,077	0,180*	-0,014	-0,005	0,004
4	0,036	0,082	0,056	-0,077	0,164*
5	-0,142	-0,028	-0,012	-0,009	-0,075
	r_{41}	r_{42}	r_{43}	r_{44}	r_{45}
1	-0,024	0,003	0,002	-0,004	0,002
2	-0,057	0,027	0,004	0,018	-0,028
3	-0,069	-0,010	-0,003	0,024	0,094
4	-0,005	-0,018	0,003	-0,030	-0,172*
5	-0,102	-0,102	-0,017	-0,052	-0,106
	r_{51}	r_{52}	r_{53}	r_{54}	r_{55}
1	0,114	-0,013	-0,009	-0,011	0,046
2	-0,061	0,063	0,015	0,076	-0,235*
3	-0,111	0,105	0,047	-0,005	-0,072
4	0,085	0,052	-0,177*	0,103	0,037
5	0,128	0,034	0,030	-0,076	0,001

DT = $\frac{2}{\sqrt{T}} = 0,161$. En * significativos al 95 %.

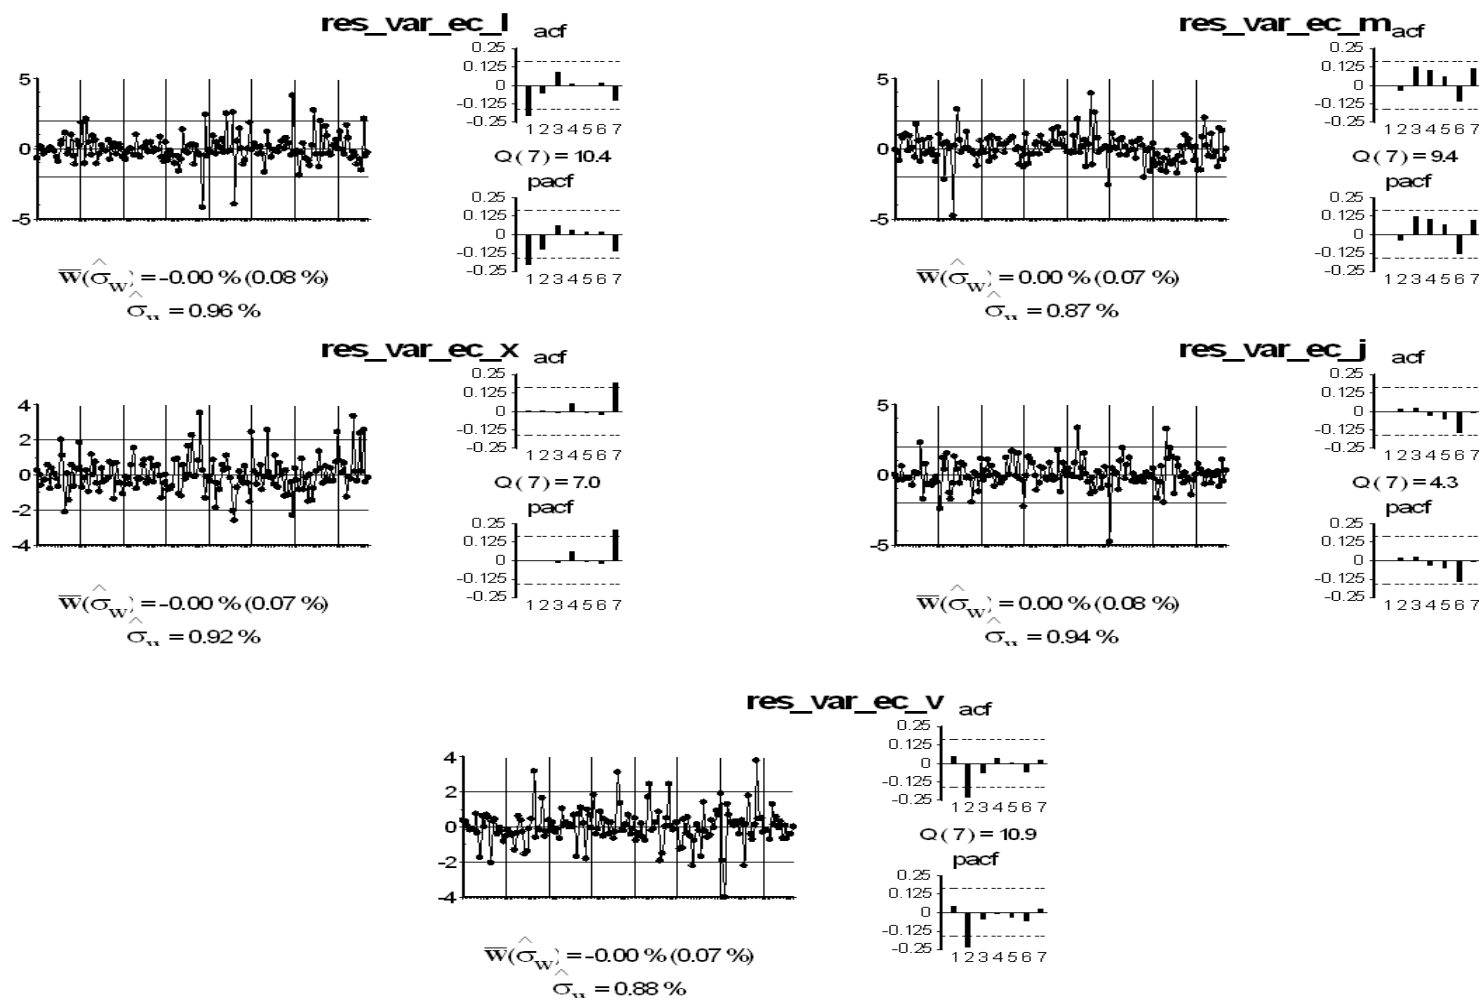


Gráfico 3.6: Abertis: Residuos del VAR(1)

3.B.3 ACS

3.B.3.1 Elección orden del VAR

En la tabla 3.13 se muestran los estadísticos de Akaike y de Schwarz para diversos ordenes del VAR.

Tabla 3.13: ACS: Elección del orden del VAR

Retardos	1	2	3	4
AIC	-31,75	-31,66	-31,55	-31,44
SC	-31,16	-30,57	-29,96	-29,35

Ambos criterios coinciden en señalar que lo más correcto es estimar un VAR(1) con constante.

3.B.3.2 Estimación modelo VAR

Se estiman de forma conjunta todos los parámetros por mínimos cuadrados generalizados. En la tabla 3.14 se muestran los resultados.

Tabla 3.14: ACS: Estimación del VAR(1) ortogonalizado

Variable dependiente	Ecuaciones ^a				
	l_t	m_t	x_t	j_t	v_t
μ	0,0025 (0,0025)	$-4,84E-05$ (0,0065)	0,017 (0,0069)	$-0,00087$ (0,0066)	$-0,00059$ (0,00541)
l_t		1,03 (0,06)	$-0,25$ (0,11)	$-0,046$ (0,108)	0,050 (0,088)
m_t			1,14 (0,09)	$-0,024$ (0,124)	0,074 (0,101)
x_t				1,04 (0,08)	$-0,49$ (0,10)
j_t					1,38 (0,07)
l_{t-1}	0,053 (0,111)	0,064 (0,082)	$-0,14$ (0,09)	$-0,084$ (0,085)	0,17 (0,07)
m_{t-1}	$-0,075$ (0,161)	$-0,038$ (0,119)	0,14 (0,13)	0,20 (0,12)	$-0,18$ (0,10)
x_{t-1}	0,037 (0,166)	$-0,039$ (0,122)	$-0,067$ (0,13)	$-0,10$ (0,12)	$-0,084$ (0,102)
j_{t-1}	$-0,21$ (0,21)	$-0,062$ (0,154)	0,045 (0,164)	0,051 (0,158)	0,18 (0,13)
v_{t-1}	1,19 (0,13)	0,049 (0,120)	0,14 (0,13)	$-0,024$ (0,124)	$-0,095$ (0,101)

^aLa tabla muestra los coeficientes estimados del modelo VAR donde cada columna representa una ecuación del mismo. Entre paréntesis se presentan las desviaciones típicas.

La matriz de covarianzas se presenta en (3.3).

$$\Sigma_u = \begin{pmatrix} 1,69E-04 & 1,73E-04 & 1,55E-04 & 1,48E-04 & 1,50E-04 \\ 1,73E-04 & 2,69E-04 & 2,63E-04 & 2,58E-04 & 2,54E-04 \\ 1,55E-04 & 2,63E-04 & 3,62E-04 & 3,62E-04 & 3,48E-04 \\ 1,48E-04 & 2,58E-04 & 3,62E-04 & 4,57E-04 & 4,78E-04 \\ 1,50E-04 & 2,54E-04 & 3,48E-04 & 4,78E-04 & 5,76E-04 \end{pmatrix} \quad (3.3)$$

Los residuos del VAR(1) aparecen en el gráfico 3.7. Por su parte, en la tabla 3.15 se muestran las funciones de correlación cruzadas. Aunque cinco correlaciones son estadísticamente distintas de 0, no parece necesario incrementar el orden del VAR(1), por lo que se considera que el modelo de la tabla 3.14 representa de forma adecuada la relación existente entre las variables.

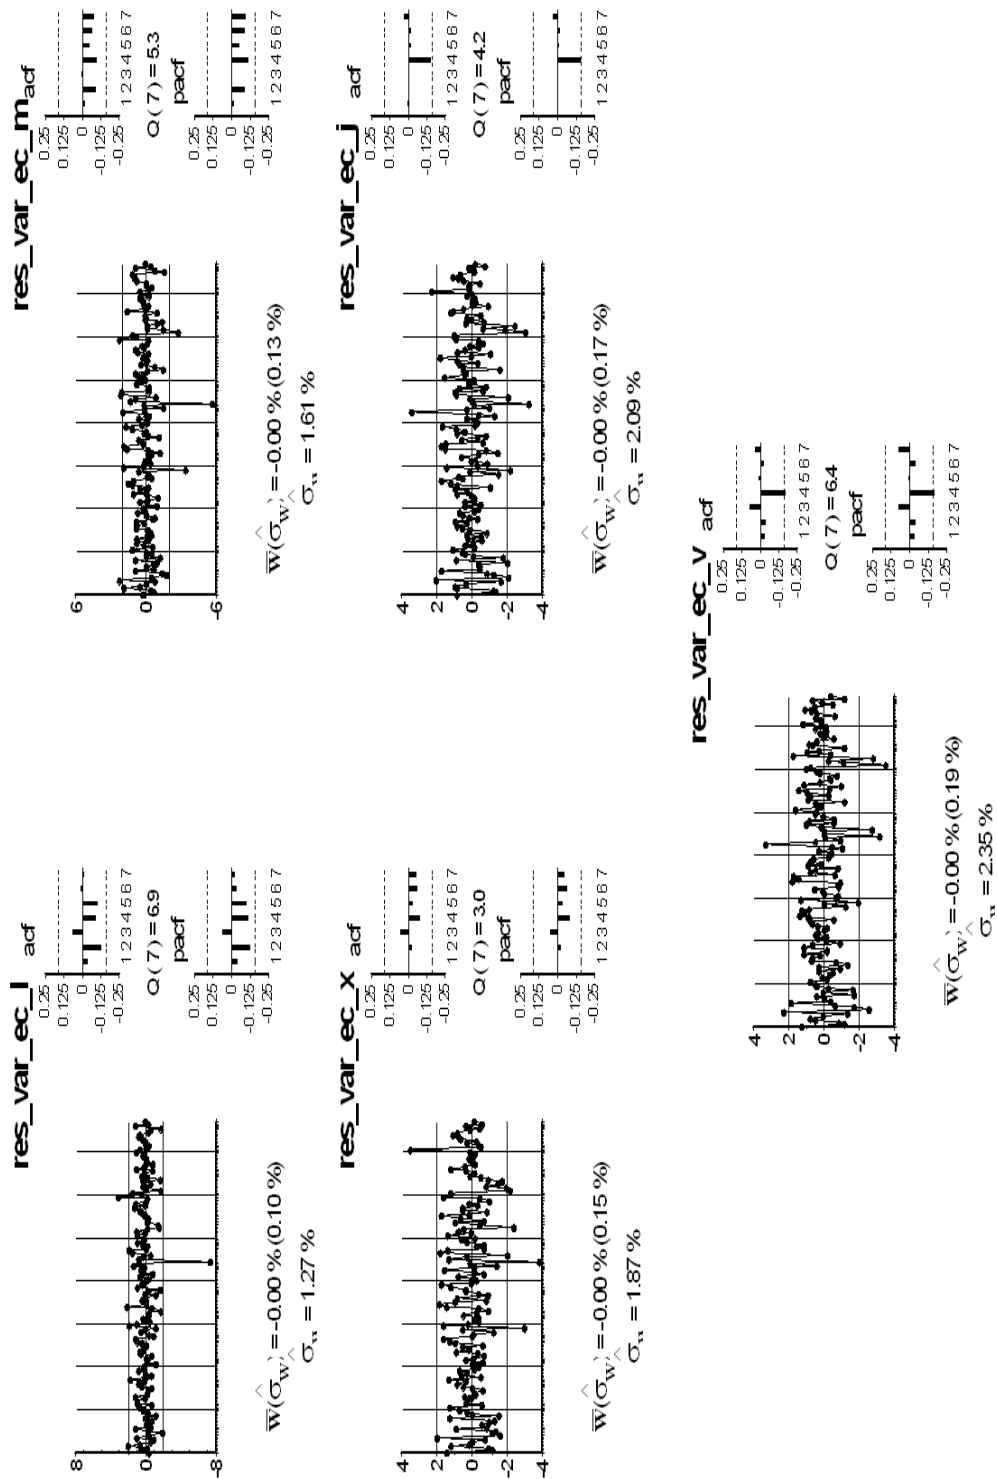


Gráfico 3.7: ACS: Residuos del VAR(1)

Tabla 3.15: ACS: Función de correlación cruzada residual del VAR(1)

Retardos	r_{11}	r_{12}	r_{13}	r_{14}	r_{15}
1	-0,038	-0,024	-0,032	-0,036	-0,028
2	-0,126	-0,023	-0,029	-0,014	-0,030
3	0,070	0,057	0,042	-0,008	-0,027
4	-0,093	-0,120	-0,075	-0,174*	-0,187*
5	-0,107	-0,018	0,019	0,022	0,019
	r_{21}	r_{22}	r_{23}	r_{24}	r_{25}
1	-0,034	-0,018	-0,023	-0,028	-0,020
2	-0,210*	-0,094	-0,076	-0,073	-0,093
3	0,000	0,003	0,002	-0,057	-0,053
4	-0,079	-0,101	-0,053	-0,106	-0,139
5	-0,144	-0,050	0,005	0,028	0,047
	r_{31}	r_{32}	r_{33}	r_{34}	r_{35}
1	-0,008	0,003	-0,003	-0,010	-0,006
2	-0,124	-0,044	-0,024	0,007	-0,018
3	0,047	0,075	0,054	-0,003	0,013
4	-0,132	-0,107	-0,085	-0,105	-0,113
5	-0,162*	-0,065	-0,035	0,019	0,051
	r_{41}	r_{42}	r_{43}	r_{44}	r_{45}
1	0,022	0,027	0,016	0,006	0,008
2	-0,109	-0,024	-0,023	-0,002	-0,030
3	0,066	0,102	0,055	-0,004	0,035
4	-0,168*	-0,145	-0,123	-0,157	-0,161*
5	-0,157	-0,092	-0,051	-0,015	0,041
	r_{51}	r_{52}	r_{53}	r_{54}	r_{55}
1	-0,049	-0,030	-0,031	-0,037	-0,032
2	-0,080	-0,022	-0,038	-0,009	-0,037
3	0,125	0,142	0,084	0,044	0,078
4	-0,125	-0,109	-0,096	-0,151	-0,169*
5	-0,157	-0,093	-0,054	-0,031	0,014

DT = $\frac{2}{\sqrt{T}} = 0,161$. En * significativos al 95 %.

3.B.4 Acerinox

3.B.4.1 Elección orden del VAR

Para determinar el orden del VAR se computan los estadísticos de Akaike y de Schwarz, que se presentan en la tabla 3.16.

Tabla 3.16: Acerinox: Elección del orden del VAR

Retardos	1	2	3	4
AIC	-30,70	-30,53	-30,33	-30,12
SC	-30,11	-29,44	-28,75	-28,03

Los dos criterios no difieren y por ello se decide estimar un VAR(1) con constante.

3.B.4.2 Estimación modelo VAR

Se estiman todos los parámetros de forma conjunta por mínimos cuadrados generalizados. Los resultados aparecen en la tabla 3.17.

Tabla 3.17: Acerinox: Estimación del VAR(1) ortogonalizado

Variable dependiente	Ecuaciones ^a				
	l_t	m_t	x_t	j_t	v_t
μ	-0,0017 (0,0122)	-0,018 (0,013)	-0,035 (0,015)	$1,24E-06$ (0,014)	0,029 (0,017)
l_t		1,11 (0,09)	$-1,64E-05$ (0,14)	0,073 (0,130)	-0,040 (0,158)
m_t			1,05 (0,09)	-0,17 (0,11)	-0,023 (0,141)
x_t				1,25 (0,07)	-0,15 (0,14)
j_t					1,21 (0,10)
l_{t-1}	0,031 (0,075)	0,035 (0,079)	-0,037 (0,090)	0,067 (0,082)	0,10 (0,10)
m_{t-1}	-0,13 (0,10)	-0,035 (0,109)	0,040 (0,124)	-0,073 (0,113)	-0,20 (0,14)
x_{t-1}	0,16 (0,11)	-0,073 (0,116)	-0,029 (0,132)	-0,086 (0,120)	-0,089 (0,146)
j_{t-1}	-0,22 (0,11)	0,31 (0,11)	-0,018 (0,134)	0,22 (0,12)	0,21 (0,15)
v_{t-1}	1,16 (0,06)	-0,34 (0,12)	0,0099 (0,14)	-0,16 (0,13)	-0,032 (0,155)

^aLa tabla muestra los coeficientes estimados del modelo VAR donde cada columna representa una ecuación del mismo. Entre paréntesis se presentan las desviaciones típicas.

La matriz de covarianzas se presenta en (3.4).

$$\Sigma_u = \begin{pmatrix} 9,62E-05 & 1,07E-04 & 1,12E-04 & 1,15E-04 & 1,16E-04 \\ 1,07E-04 & 2,26E-04 & 2,37E-04 & 2,36E-04 & 2,41E-04 \\ 1,12E-04 & 2,37E-04 & 3,87E-04 & 4,03E-04 & 4,20E-04 \\ 1,15E-04 & 2,36E-04 & 4,03E-04 & 5,35E-04 & 5,77E-04 \\ 1,16E-04 & 2,41E-04 & 4,20E-04 & 5,77E-04 & 7,90E-04 \end{pmatrix} \quad (3.4)$$

En el gráfico 3.8 se presentan los residuos del VAR(1), mientras que la función de correlación cruzada aparece en la tabla 3.18. Sólo una de las correlación cruzada es significativa, por lo que se considera que el modelo de la tabla 3.17 representa de forma adecuada la correlación dinámica entre las variables.

Tabla 3.18: Acerinox: Función de correlación cruzada residual del VAR(1)

Retardos	r_{11}	r_{12}	r_{13}	r_{14}	r_{15}
1	-0,045	-0,031	-0,025	-0,027	-0,034
2	0,116	0,021	0,101	0,111	0,082
3	0,044	-0,030	0,011	0,035	-0,024
4	-0,090	-0,143	-0,122	-0,114	-0,139
5	0,027	0,004	0,014	0,027	-0,001
	r_{21}	r_{22}	r_{23}	r_{24}	r_{25}
1	-0,080	-0,044	-0,037	-0,032	-0,037
2	0,059	0,033	0,164*	0,160	0,148
3	0,034	-0,017	0,037	0,042	-0,036
4	-0,092	-0,126	-0,118	-0,050	-0,066
5	0,034	-0,011	-0,033	0,030	0,016
	r_{31}	r_{32}	r_{33}	r_{34}	r_{35}
1	-0,100	-0,072	-0,058	-0,053	-0,049
2	0,024	0,063	0,145	0,140	0,095
3	0,027	0,012	0,031	0,012	-0,060
4	-0,050	-0,034	-0,036	0,002	-0,006
5	0,119	0,038	0,052	0,109	0,083
	r_{41}	r_{42}	r_{43}	r_{44}	r_{45}
1	-0,074	-0,056	-0,044	-0,040	-0,036
2	0,029	0,038	0,115	0,092	0,051
3	0,036	0,015	0,053	0,021	-0,040
4	-0,075	-0,026	-0,038	-0,002	-0,007
5	0,090	0,058	0,066	0,094	0,092
	r_{51}	r_{52}	r_{53}	r_{54}	r_{55}
1	-0,092	-0,071	-0,054	-0,050	-0,045
2	0,041	0,030	0,097	0,074	0,035
3	-0,043	-0,002	0,033	0,005	-0,017
4	-0,044	-0,015	-0,021	0,023	0,012
5	0,075	0,094	0,093	0,089	0,082

DT = $\frac{2}{\sqrt{T}} = 0,161$. En * significativos al 95 %.

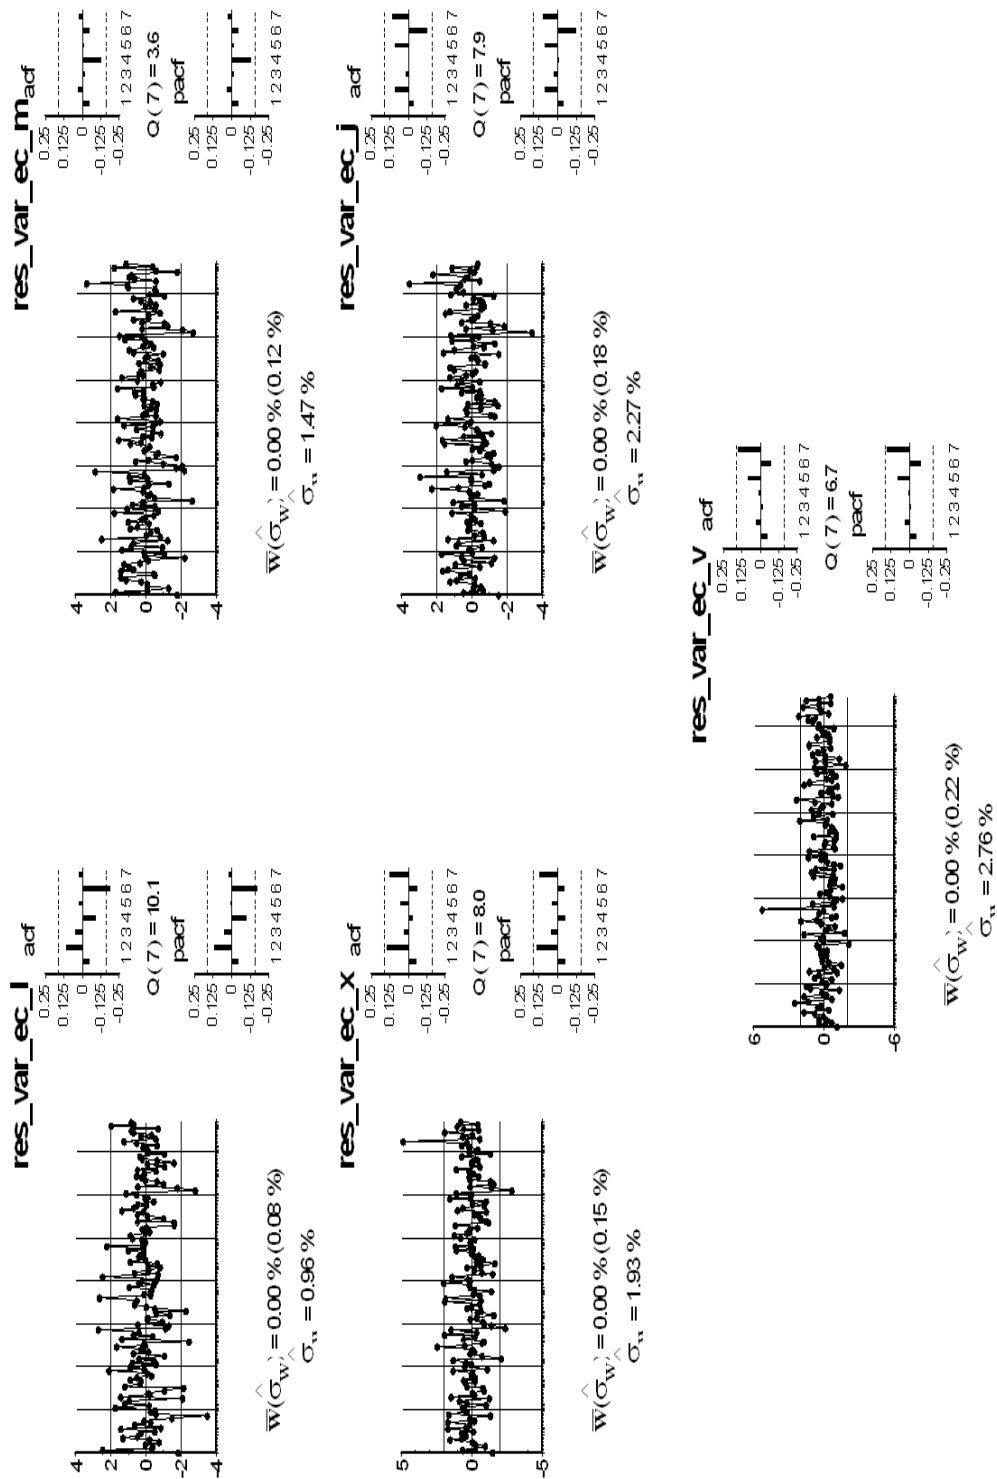


Gráfico 3.8: Acerinox: Residuos del VAR(1)

3.B.5 Altadis

3.B.5.1 Elección orden del VAR

En la tabla 3.19 se muestran los estadísticos de Akaike y de Schwarz para diversos ordenes del VAR.

Tabla 3.19: Altadis: Elección del orden del VAR

Retardos	1	2	3	4
AIC	-31.69	-31.50	-31.44	-31.31
SC	-31.10	-30.41	-29.86	-29.22

Los dos criterios coinciden en señalar que se debe estimar un VAR(1).

3.B.5.2 Estimación modelo VAR

Se estiman, por mínimos cuadrados generalizados, todos los parámetros de forma conjunta. Los resultados aparecen en la tabla 3.20.

Tabla 3.20: Altadis: Estimación del VAR(1) ortogonalizado

Variable dependiente	Ecuaciones ^a				
	l_t	m_t	x_t	j_t	v_t
μ	0,024 (0,017)	0,0094 (0,0151)	0,024 (0,017)	-0,0031 (0,0234)	0,026 (0,016)
l_t		1,12 (0,07)	-0,24 (0,13)	0,073 (0,130)	-0,15 (0,12)
m_t			1,22 (0,09)	-0,14 (0,18)	0,21 (0,13)
x_t				1,09 (0,11)	-0,36 (0,10)
j_t					1,10 (0,06)
l_{t-1}	-0,21 (0,09)	0,045 (0,083)	-0,20 (0,09)	0,12 (0,13)	0,046 (0,088)
m_{t-1}	0,19 (0,14)	-0,11 (0,12)	0,21 (0,14)	-0,11 (0,18)	-0,12 (0,13)
x_{t-1}	0,12 (0,11)	0,17 (0,09)	-0,030 (0,110)	0,095 (0,148)	0,066 (0,101)
j_{t-1}	-0,13 (0,11)	-0,064 (0,100)	0,14 (0,11)	-0,015 (0,155)	0,052 (0,106)
v_{t-1}	1,02 (0,09)	-0,16 (0,10)	-0,11 (0,12)	-0,10 (0,16)	0,15 (0,11)

^aLa tabla muestra los coeficientes estimados del modelo VAR donde cada columna representa una ecuación del mismo. Entre paréntesis se presentan las desviaciones típicas.

La matriz de covarianzas se presenta en (3.5).

$$\Sigma_u = \begin{pmatrix} 1,00E-04 & 1,12E-04 & 1,13E-04 & 1,14E-04 & 9,31E-05 \\ 1,12E-04 & 2,00E-04 & 2,17E-04 & 2,16E-04 & 1,85E-04 \\ 1,13E-04 & 2,17E-04 & 3,33E-04 & 3,40E-04 & 2,83E-04 \\ 1,14E-04 & 2,16E-04 & 3,40E-04 & 5,21E-04 & 4,78E-04 \\ 9,31E-05 & 1,85E-04 & 2,83E-04 & 4,78E-04 & 5,28E-04 \end{pmatrix} \quad (3.5)$$

En el gráfico 3.9 aparecen los residuos del VAR(1). Por otro lado, en la tabla 3.21 se presentan las funciones de correlación cruzadas. Aparecen cinco correlaciones significativas, sin embargo se considera que el modelo de la tabla 3.20 representa adecuadamente la relación entre las variables.

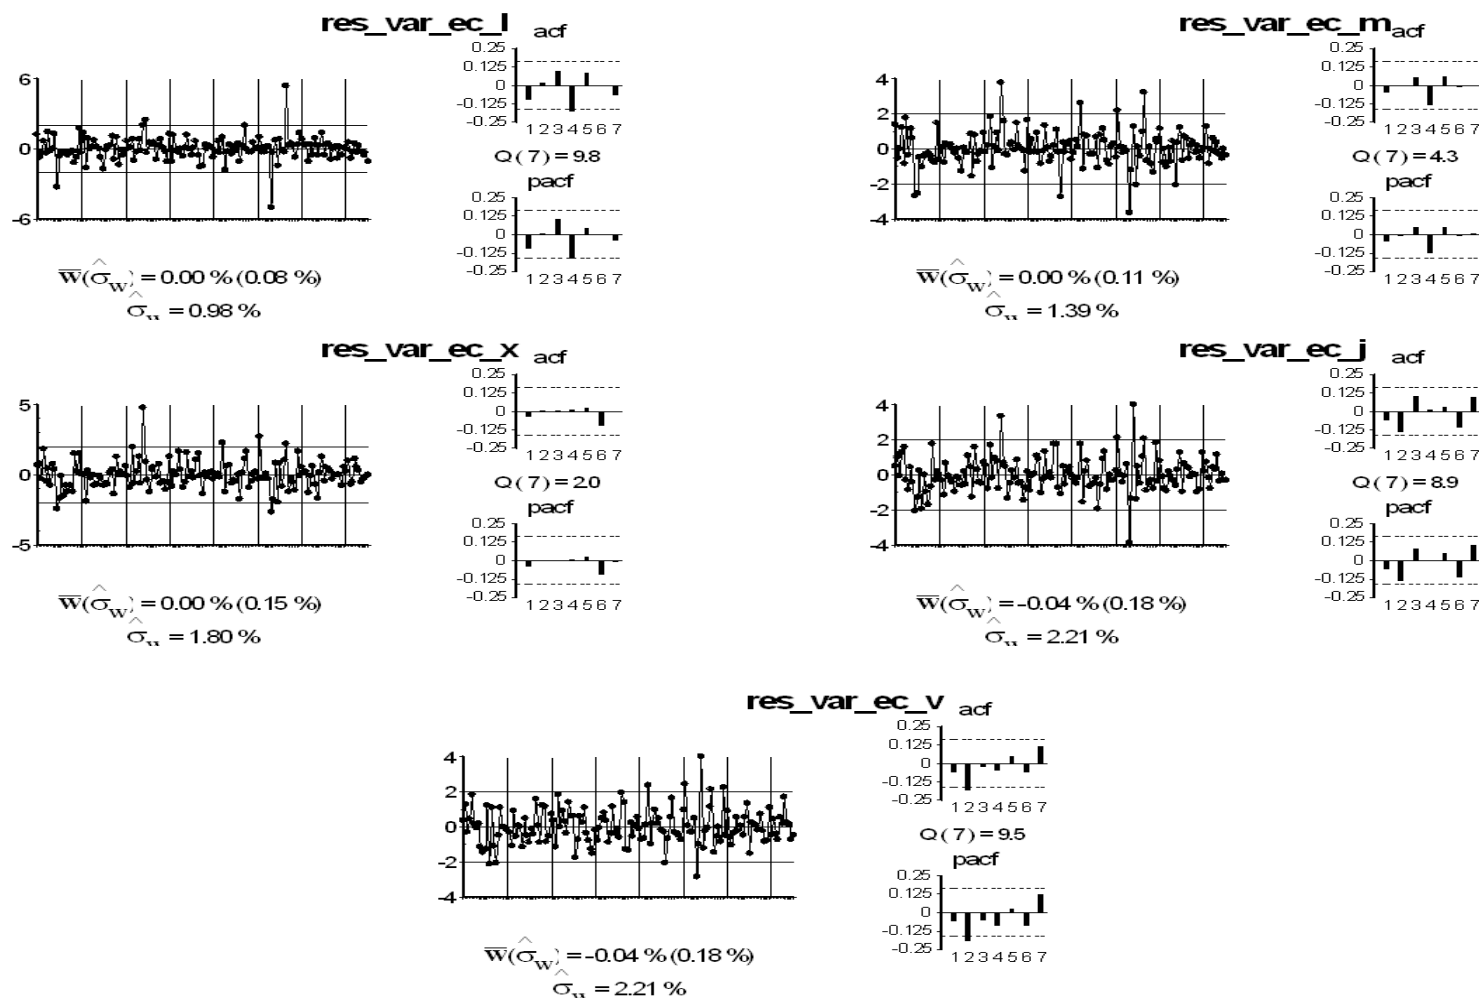


Gráfico 3.9: Altadis: Residuos del VAR(1)

Tabla 3.21: Altadis: Función de correlación cruzada residual del VAR(1)

Retardos	r_{11}	r_{12}	r_{13}	r_{14}	r_{15}
1	-0,087	-0,060	-0,031	-0,025	-0,026
2	0,017	-0,035	-0,048	-0,037	-0,009
3	0,092	0,113	0,148	0,178*	0,108
4	-0,176*	-0,181*	-0,061	-0,067	-0,102
5	0,071	0,037	-0,053	0,037	0,023
	r_{21}	r_{22}	r_{23}	r_{24}	r_{25}
1	-0,065	-0,055	-0,032	-0,029	-0,028
2	0,020	0,001	0,010	-0,036	-0,010
3	0,010	0,052	0,039	0,099	0,039
4	-0,121	-0,133	0,002	0,019	-0,036
5	0,083	0,063	-0,004	0,070	0,046
	r_{31}	r_{32}	r_{33}	r_{34}	r_{35}
1	-0,079	-0,067	-0,046	-0,043	-0,044
2	0,017	-0,007	0,010	-0,037	-0,037
3	0,022	0,030	0,003	0,071	-0,008
4	-0,096	-0,075	0,010	0,047	-0,004
5	0,160	0,124	0,025	0,082	0,060
	r_{41}	r_{42}	r_{43}	r_{44}	r_{45}
1	-0,075	-0,078	-0,059	-0,061	-0,060
2	-0,118	-0,089	-0,044	-0,146	-0,161*
3	0,003	-0,007	0,016	0,104	0,030
4	-0,079	-0,078	-0,031	0,006	-0,018
5	0,135	0,077	-0,010	0,046	0,049
	r_{51}	r_{52}	r_{53}	r_{54}	r_{55}
1	-0,062	-0,073	-0,052	-0,057	-0,058
2	-0,142	-0,131	-0,077	-0,196*	-0,205*
3	-0,017	-0,023	-0,001	0,068	-0,018
4	-0,083	-0,060	-0,047	-0,006	-0,034
5	0,149	0,095	0,003	0,054	0,075

DT = $\frac{2}{\sqrt{T}} = 0,161$. En * significativos al 95 %.

3.B.6 Acciona

3.B.6.1 Elección orden del VAR

Los estadísticos de Akaike y de Schwarz se muestran en la tabla 3.22. Los dos criterios no difieren y por ello se decide estimar un VAR(1).

Tabla 3.22: Acciona: Elección del orden del VAR

Retardos	1	2	3	4
AIC	-28,99	-28,85	-28,76	-28,71
SC	-28,40	-27,76	-27,17	-26,62

3.B.6.2 Estimación modelo VAR

Se estiman todos los parámetros de forma conjunta por mínimos cuadrados generalizados. Los resultados aparecen en la tabla 3.23.

Tabla 3.23: Acciona: Estimación del VAR(1) ortogonalizado

Variable dependiente	Ecuaciones ^a				
	l_t	m_t	x_t	j_t	v_t
μ	0,00045 (0,01124)	0,0056 (0,0125)	0,00098 (0,0137)	0,012 (0,014)	-0,0029 (0,0128)
l_t		1,03 (0,09)	-0,069 (0,136)	0,11 (0,14)	-0,12 (0,08)
m_t			1,08 (0,09)	-0,16 (0,13)	0,011 (0,118)
x_t				1,10 (0,09)	-0,093 (0,116)
j_t					1,07 (0,07)
l_{t-1}	-0,13 (0,07)	-0,11 (0,08)	0,073 (0,088)	0,12 (0,09)	0,12 (0,08)
m_{t-1}	0,19 (0,10)	0,20 (0,11)	-0,15 (0,12)	-0,23 (0,13)	0,011 (0,112)
x_{t-1}	-0,12 (0,10)	-0,31 (0,11)	0,072 (0,123)	0,24 (0,13)	-0,093 (0,116)
j_{t-1}	-0,041 (0,100)	0,23 (0,11)	-0,070 (0,123)	-0,18 (0,13)	-0,087 (0,115)
v_{t-1}	1,11 (0,07)	-0,038 (0,13)	0,10 (0,14)	-0,0097 (0,1486)	0,18 (0,13)

^aLa tabla muestra los coeficientes estimados del modelo VAR donde cada columna representa una ecuación del mismo. Entre paréntesis se presentan las desviaciones típicas.

La matriz de covarianzas se presenta en (3.6).

$$\Sigma_u = \begin{pmatrix} 1,32E-04 & 1,35E-04 & 1,31E-04 & 1,38E-04 & 1,21E-04 \\ 1,35E-04 & 3,02E-04 & 3,04E-04 & 3,02E-04 & 2,83E-04 \\ 1,31E-04 & 3,04E-04 & 4,99E-04 & 5,17E-04 & 4,99E-04 \\ 1,38E-04 & 3,02E-04 & 5,17E-04 & 7,50E-04 & 7,48E-04 \\ 1,21E-04 & 2,83E-04 & 4,99E-04 & 7,48E-04 & 9,15E-04 \end{pmatrix} \quad (3.6)$$

En la tabla 3.24 se presentan las funciones de correlación cruzadas, donde se observa que tres de ellas son estadísticamente distintas de cero, una de ellas en el primer retardo. Sin embargo se considera que el modelo de la tabla 3.23 representa de forma adecuada la correlación. La representación gráfica de los residuos del VAR(1) aparece en el gráfico 3.10.

Tabla 3.24: Acciona: Función de correlación cruzada residual del VAR(1)

Retardos	r_{11}	r_{12}	r_{13}	r_{14}	r_{15}
1	0,011	0,023	0,021	0,011	0,025
2	-0,042	0,120	0,160	0,056	0,058
3	0,059	-0,015	0,080	0,107	0,137
4	0,029	-0,007	0,012	-0,025	0,006
5	-0,060	0,041	0,055	0,066	0,059
	r_{21}	r_{22}	r_{23}	r_{24}	r_{25}
1	-0,062	-0,039	-0,030	-0,025	-0,013
2	0,005	0,080	0,099	0,058	0,051
3	0,057	-0,07	0,054	0,088	0,088
4	0,028	0,089	0,018	0,034	0,038
5	0,027	0,180*	0,107	0,158	0,142
	r_{31}	r_{32}	r_{33}	r_{34}	r_{35}
1	-0,128	-0,085	-0,074	-0,066	-0,053
2	0,085	0,080	0,138	0,130	0,148
3	0,053	-0,022	0,009	0,000	-0,020
4	0,061	0,127	0,082	0,061	0,073
5	0,027	0,100	0,029	0,075	0,060
	r_{41}	r_{42}	r_{43}	r_{44}	r_{45}
1	-0,124	-0,076	-0,067	-0,063	-0,044
2	0,059	0,070	0,167*	0,148	0,152
3	0,040	0,016	0,013	0,039	0,039
4	0,035	0,060	-0,001	-0,047	-0,039
5	0,049	0,054	0,005	0,050	0,026
	r_{51}	r_{52}	r_{53}	r_{54}	r_{55}
1	-0,172*	-0,114	-0,097	-0,085	-0,069
2	-0,027	0,001	0,089	0,099	0,121
3	-0,014	-0,010	0,004	0,005	-0,005
4	0,048	0,099	0,018	-0,023	-0,040
5	0,025	0,060	0,033	0,096	0,058

DT = $\frac{2}{\sqrt{T}} = 0,161$. En * significativos al 95 %.

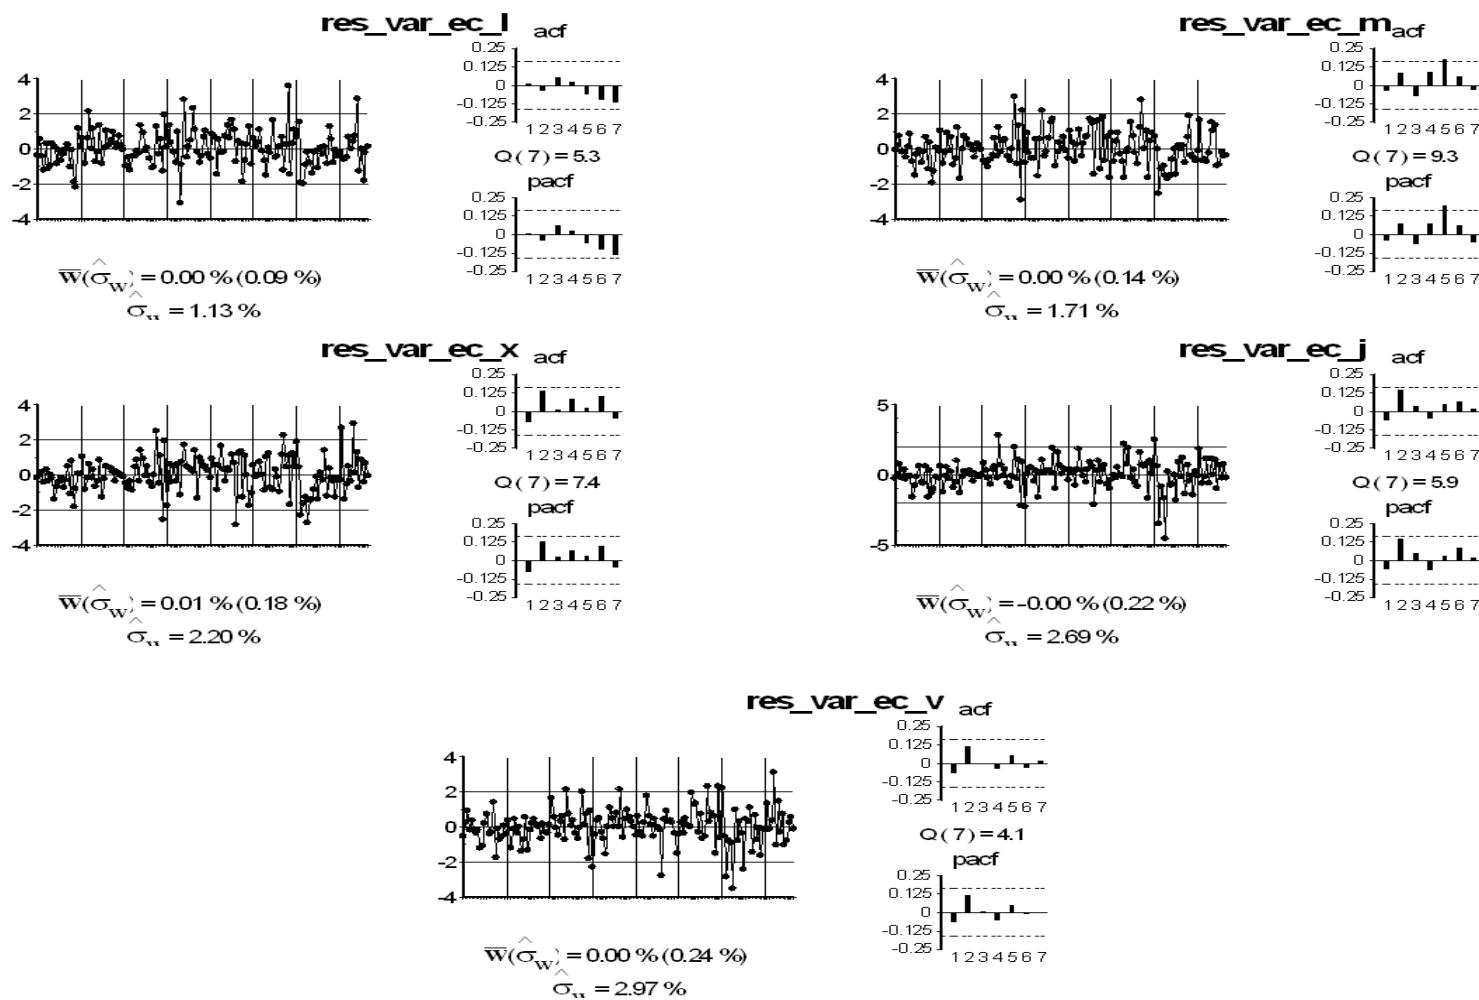


Gráfico 3.10: Acciona: Residuos del VAR(1)

3.B.7 BBVA

3.B.7.1 Elección orden del VAR

Para determinar el orden del VAR se calculan los estadísticos de Akaike y de Schwarz que aparecen en la tabla 3.25.

Tabla 3.25: BBVA: Elección del orden del VAR

Retardos	1	2	3	4
AIC	-32,41	-32,40	-32,19	-32,11
SC	-31,82	-31,32	-30,61	-30,02

Al coincidir los dos estadísticos, se decide estimar un VAR(1).

3.B.7.2 Estimación modelo VAR

Se estiman todos los parámetros de forma conjunta por mínimos cuadrados generalizados. Los resultados aparecen en la tabla 3.26.

Tabla 3.26: BBVA: Estimación del VAR(1) ortogonalizado

Variable dependiente	Ecuaciones ^a				
	l_t	m_t	x_t	j_t	v_t
l_t		1,10 (0,05)	-0,22 (0,11)	-0,0057 (0,1277)	0,040 (0,118)
m_t			1,14 (0,09)	-0,19 (0,14)	-0,048 (0,133)
x_t				1,19 (0,09)	-0,24 (0,12)
j_t					1,26 (0,08)
l_{t-1}	-0,092 (0,120)	-0,10 (0,08)	0,044 (0,087)	0,041 (0,097)	0,11 (0,09)
m_{t-1}	0,27 (0,17)	0,071 (0,118)	-0,11 (0,13)	-0,015 (0,142)	-0,12 (0,13)
x_{t-1}	-0,27 (0,17)	0,041 (0,113)	0,17 (0,12)	-0,036 (0,136)	0,081 (0,126)
j_{t-1}	0,082 (0,175)	-0,019 (0,117)	-0,11 (0,13)	-0,074 (0,141)	-0,12 (0,13)
v_{t-1}	0,99 (0,11)	-0,090 (0,090)	0,089 (0,100)	0,088 (0,111)	0,045 (0,103)

^aLa tabla muestra los coeficientes estimados del modelo VAR donde cada columna representa una ecuación del mismo. Entre paréntesis se presentan las desviaciones típicas.

La matriz de covarianzas se presenta en 3.7.

$$\Sigma_u = \begin{pmatrix} 1,44E-04 & 1,58E-04 & 1,48E-04 & 1,46E-04 & 1,47E-04 \\ 1,58E-04 & 2,38E-04 & 2,36E-04 & 2,36E-04 & 2,36E-04 \\ 1,48E-04 & 2,36E-04 & 3,10E-04 & 3,25E-04 & 3,30E-04 \\ 1,46E-04 & 2,36E-04 & 3,25E-04 & 4,33E-04 & 4,63E-04 \\ 1,47E-04 & 2,36E-04 & 3,30E-04 & 4,63E-04 & 5,77E-04 \end{pmatrix} \quad (3.7)$$

En la tabla 3.27 se presentan las funciones de correlación cruzadas. En ella aparecen cuatro correlaciones significativas, sin embargo, se considera que el modelo de la tabla 3.26 representa de forma adecuada la dinámica de las variables. El gráfico 3.11 muestra los residuos del VAR(1).

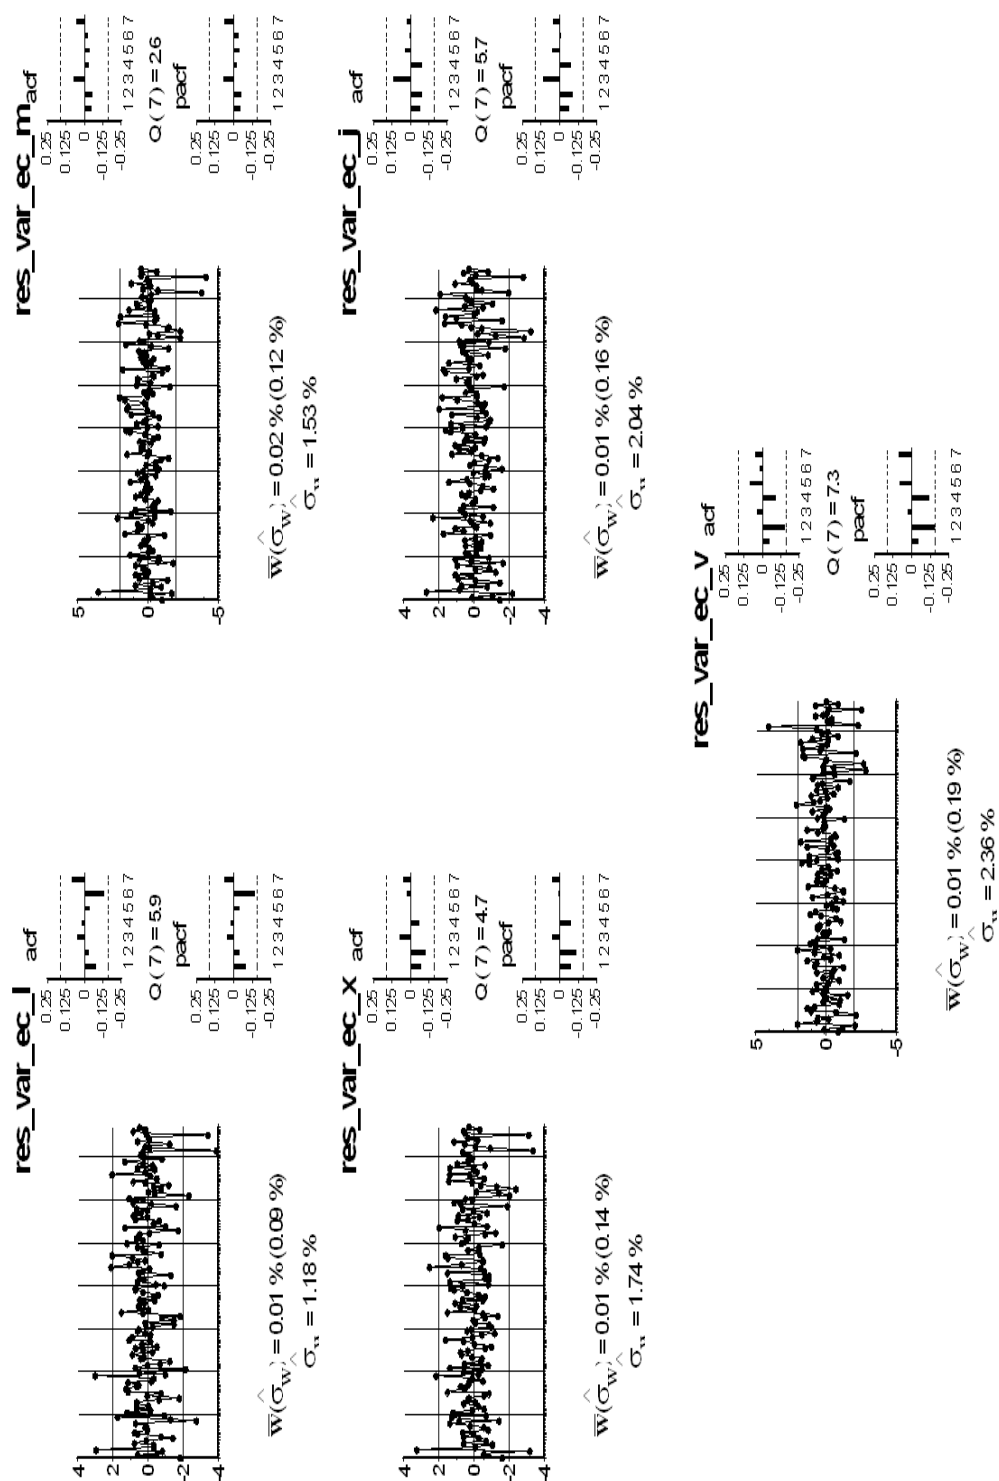


Gráfico 3.11: BBVA: Residuos del VAR(1)

Tabla 3.27: BBVA: Función de correlación cruzada residual del VAR(1)

Retardos	r_{11}	r_{12}	r_{13}	r_{14}	r_{15}
1	-0,082	-0,051	-0,041	-0,038	-0,036
2	-0,035	-0,079	-0,083	-0,071	-0,106
3	0,050	0,043	0,036	0,037	0,016
4	0,015	0,035	0,019	-0,017	-0,050
5	-0,043	-0,034	0,039	0,115	0,136
	r_{21}	r_{22}	r_{23}	r_{24}	r_{25}
1	-0,071	-0,045	-0,036	-0,029	-0,024
2	-0,009	-0,054	-0,091	-0,100	-0,164*
3	0,095	0,073	0,070	0,098	0,077
4	-0,015	-0,030	-0,042	-0,031	-0,029
5	-0,040	-0,037	0,006	0,072	0,089
	r_{31}	r_{32}	r_{33}	r_{34}	r_{35}
1	-0,128	-0,088	-0,073	-0,061	-0,053
2	-0,039	-0,074	-0,108	-0,121	-0,191*
3	0,089	0,064	0,073	0,098	0,064
4	-0,038	-0,055	-0,065	-0,029	-0,010
5	-0,041	-0,030	-0,006	0,055	0,091
	r_{41}	r_{42}	r_{43}	r_{44}	r_{45}
1	-0,142	-0,098	-0,083	-0,069	-0,058
2	-0,053	-0,090	-0,094	-0,086	-0,162*
3	0,174*	0,123	0,113	0,122	0,106
4	-0,080	-0,102	-0,110	-0,080	-0,074
5	-0,063	-0,051	-0,004	0,040	0,071
	r_{51}	r_{52}	r_{53}	r_{54}	r_{55}
1	-0,125	-0,085	-0,077	-0,060	-0,051
2	-0,050	-0,103	-0,058	-0,053	-0,155
3	0,152	0,098	0,068	0,055	0,038
4	-0,029	-0,060	-0,091	-0,095	-0,090
5	-0,073	-0,049	-0,001	0,038	0,082

DT = $\frac{2}{\sqrt{T}} = 0,161$. En * significativos al 95 %.

3.B.8 Bankinter

3.B.8.1 Elección orden del VAR

En la tabla 3.28 se muestran los estadísticos de Akaike y de Schwarz para diversos ordenes del VAR. En ella se observa que ambos criterios coinciden por lo que se estima un VAR(1) con constante.

Tabla 3.28: Bankinter: Elección del orden del VAR

Retardos	1	2	3	4
AIC	-31,46	-31,37	-31,18	-31,12
SC	-30,87	-30,29	-29,60	-29,03

3.B.8.2 Estimación modelo VAR

Todos los parámetros del modelo se estiman de forma conjunta por mínimos cuadrados generalizados. Los resultados aparecen en la tabla 3.29.

Tabla 3.29: Bankinter: Estimación del VAR(1) ortogonalizado

Variable dependiente	Ecuaciones ^a				
	l_t	m_t	x_t	j_t	v_t
μ	-0,0025 (0,0085)	0,0084 (0,0074)	0,015 (0,008)	-0,027 (0,011)	0,0055 (0,0055)
l_t		0,99 (0,07)	-0,10 (0,11)	0,20 (0,18)	-0,070 (0,127)
m_t			1,16 (0,09)	-0,26 (0,19)	0,060 (0,143)
x_t				1,18 (0,12)	0,12 (0,12)
j_t					0,84 (0,06)
l_{t-1}	-0,062 (0,094)	-0,11 (0,08)	-0,0068 (0,0867)	0,11 (0,13)	0,10 (0,09)
m_{t-1}	-0,029 (0,139)	0,19 (0,12)	-0,095 (0,129)	0,12 (0,19)	-0,057 (0,142)
x_{t-1}	0,079 (0,113)	-0,033 (0,099)	0,12 (0,10)	-0,11 (0,15)	-0,074 (0,115)
j_{t-1}	-0,33 (0,09)	0,0079 (0,0828)	-0,027 (0,087)	-0,26 (0,13)	0,038 (0,097)
v_{t-1}	1,34 (0,08)	-0,049 (0,119)	-0,051 (0,125)	0,021 (0,184)	0,033 (0,138)

^aLa tabla muestra los coeficientes estimados del modelo VAR donde cada columna representa una ecuación del mismo. Entre paréntesis se presentan las desviaciones típicas.

La matriz de covarianzas se presenta en (3.8).

$$\Sigma_u = \begin{pmatrix} 1,02E-04 & 1,01E-04 & 1,07E-04 & 1,21E-04 & 1,14E-04 \\ 1,01E-04 & 1,78E-04 & 1,96E-04 & 2,06E-04 & 2,01E-04 \\ 1,07E-04 & 1,96E-04 & 3,00E-04 & 3,26E-04 & 3,16E-04 \\ 1,21E-04 & 2,06E-04 & 3,26E-04 & 5,38E-04 & 4,98E-04 \\ 1,14E-04 & 2,01E-04 & 3,16E-04 & 4,98E-04 & 5,65E-04 \end{pmatrix} \quad (3.8)$$

El gráfico 3.12 muestra los residuos del VAR(1). Por otro lado, en la tabla 3.30 se presentan las funciones de correlación cruzadas. Cuatro de las correlaciones son significativas, sin embargo, se considera que el modelo de la tabla 3.29 representa de forma adecuada la correlación dinámica entre las variables.

Tabla 3.30: Bankinter: Función de correlación cruzada residual del VAR(1)

Retardos	r_{11}	r_{12}	r_{13}	r_{14}	r_{15}
1	-0,040	-0,021	-0,019	0,002	0,002
2	0,023	0,055	0,096	0,147	0,160
3	0,148	0,123	0,072	0,050	0,077
4	-0,044	-0,023	0,027	0,070	0,106
5	-0,094	-0,032	0,009	0,089	0,068
	r_{21}	r_{22}	r_{23}	r_{24}	r_{25}
1	0,001	0,006	0,002	0,011	0,010
2	0,028	0,026	0,069	0,065	0,061
3	0,036	0,125	0,079	0,036	0,057
4	0,039	0,022	0,066	0,064	0,118
5	-0,134	-0,072	0,011	0,048	0,091
	r_{31}	r_{32}	r_{33}	r_{34}	r_{35}
1	0,024	0,018	0,007	0,013	0,017
2	0,025	0,061	0,103	0,062	0,073
3	0,092	0,158	0,096	0,058	0,078
4	0,032	0,055	0,112	0,057	0,133
5	-0,178*	-0,085	0,000	0,016	0,064
	r_{41}	r_{42}	r_{43}	r_{44}	r_{45}
1	0,008	0,003	-0,005	0,006	0,008
2	-0,016	0,006	0,073	-0,007	-0,043
3	0,176*	0,136	0,049	0,042	0,072
4	-0,042	0,008	0,055	-0,010	0,046
5	-0,030	0,006	0,098	0,192*	0,168*
	r_{51}	r_{52}	r_{53}	r_{54}	r_{55}
1	-0,072	-0,050	-0,045	-0,016	-0,016
2	-0,007	-0,017	0,065	0,029	-0,010
3	0,079	0,107	0,032	-0,021	0,020
4	-0,084	-0,010	0,059	-0,009	0,023
5	-0,081	-0,041	0,036	0,142	0,128

DT = $\frac{2}{\sqrt{T}} = 0,161$. En * significativos al 95 %.

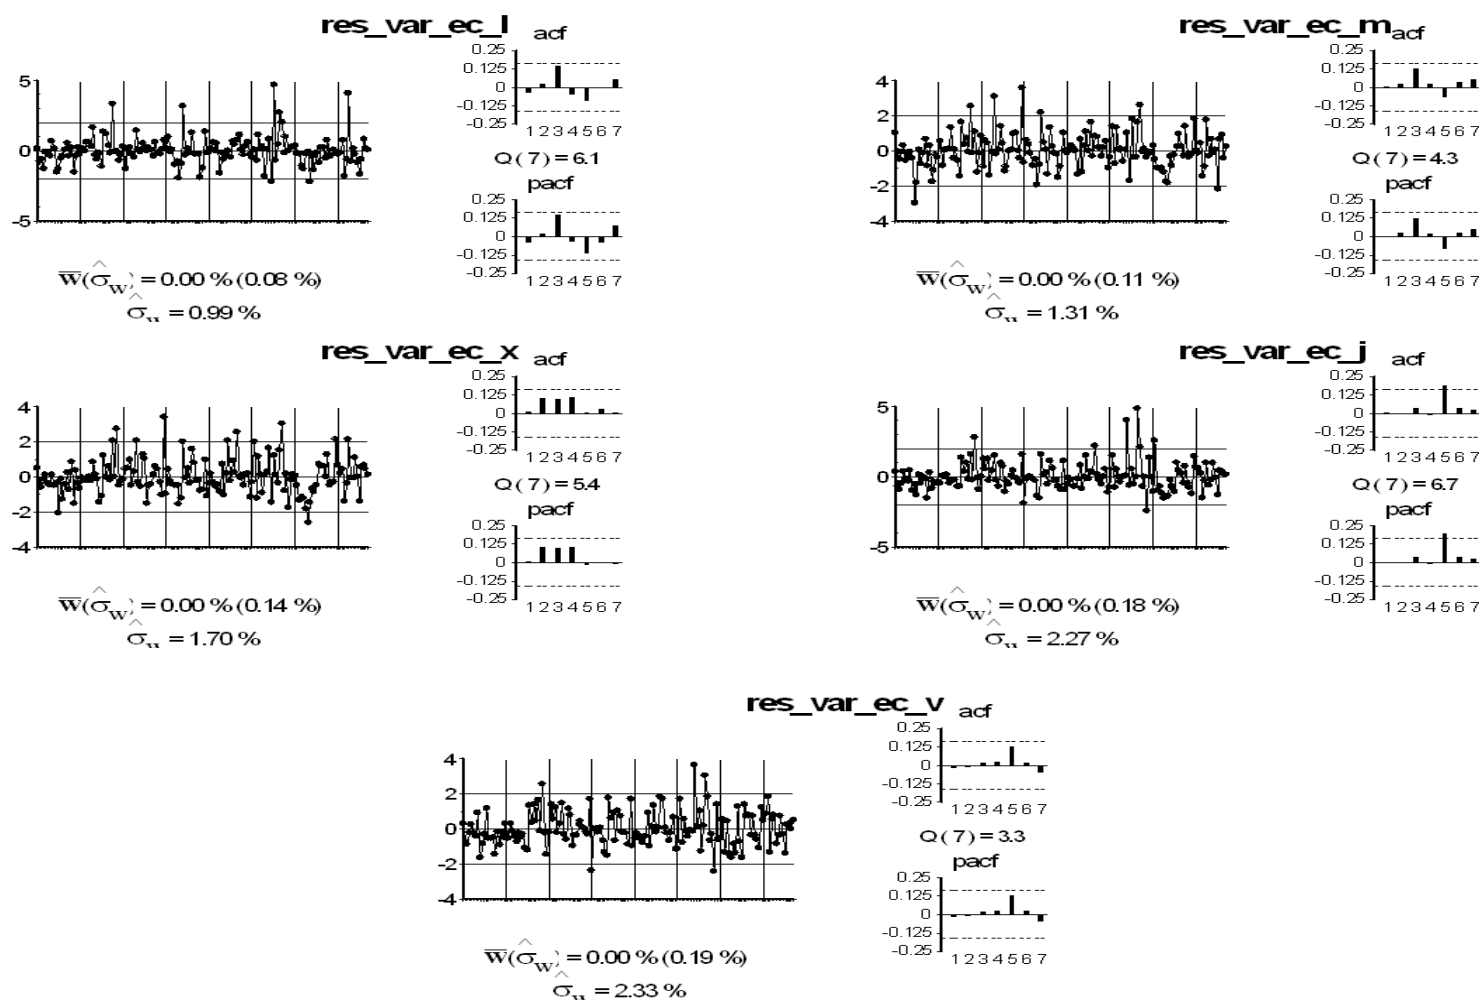


Gráfico 3.12: Bankinter: Residuos del VAR(1)

3.B.9 Banesto

3.B.9.1 Elección orden del VAR

En la tabla 3.31 se muestran los estadísticos de Akaike y de Schwarz para diversos ordenes del VAR.

Tabla 3.31: Banesto: Elección del orden del VAR

Retardos	1	2	3	4
AIC	-33,44	-33,31	-33,29	-33,07
SC	-32,85	-32,23	-31,70	-30,98

Los dos criterios no difieren al señalar que se debe estimar un VAR(1).

3.B.9.2 Estimación modelo VAR

En la tabla 3.32 aparece la estimación por mínimos cuadrados generalizados.

Tabla 3.32: Banesto: Estimación del VAR(1) ortogonalizado

Variable dependiente	Ecuaciones ^a				
	l_t	m_t	x_t	j_t	v_t
μ	0,013 (0,011)	0,0050 (0,0090)	0,0037 (0,0102)	-0,013 (0,009)	-0,013 (0,014)
l_t		1,27 (0,07)	-0,19 (0,14)	-0,069 (0,124)	0,027 (0,191)
m_t			1,12 (0,09)	-0,050 (0,114)	0,16 (0,18)
x_t				1,17 (0,07)	-0,75 (0,18)
j_t					1,44 (0,13)
l_{t-1}	-0,053 (0,095)	0,034 (0,079)	0,00037 (0,08952)	0,22 (0,08)	-0,18 (0,12)
m_{t-1}	0,091 (0,134)	0,068 (0,111)	-0,027 (0,126)	-0,29 (0,11)	0,014 (0,172)
x_{t-1}	-0,31 (0,15)	-0,052 (0,127)	0,15 (0,14)	0,089 (0,126)	0,33 (0,19)
j_{t-1}	0,30 (0,13)	-0,0064 (0,1129)	-0,056 (0,128)	0,021 (0,111)	-0,28 (0,17)
v_{t-1}	0,97 (0,06)	-0,32 (0,08)	0,0049 (0,1003)	-0,087 (0,087)	0,23 (0,13)

^aLa tabla muestra los coeficientes estimados del modelo VAR donde cada columna representa una ecuación del mismo. Entre paréntesis se presentan las desviaciones típicas.

La matriz de covarianzas se presenta en (3.9).

$$\Sigma_u = \begin{pmatrix} 7,83E-05 & 9,98E-05 & 9,70E-05 & 1,03E-04 & 9,44E-05 \\ 9,98E-05 & 1,80E-04 & 1,83E-04 & 1,98E-04 & 1,81E-04 \\ 9,70E-05 & 1,83E-04 & 2,55E-04 & 2,81E-04 & 2,48E-04 \\ 1,03E-04 & 1,98E-04 & 2,81E-04 & 3,62E-04 & 3,48E-04 \\ 9,44E-05 & 1,81E-04 & 2,48E-04 & 3,48E-04 & 4,68E-04 \end{pmatrix} \quad (3.9)$$

Los residuos del VAR(1) aparecen en el gráfico 3.13. Por su parte, en la tabla 3.33 se presentan las funciones de correlación cruzadas. Nueve de ellas son significativas, algunas de ellas en el segundo retardo, sin embargo, de momento no se incrementa el orden del VAR estimado y se considera que el modelo de la tabla 3.32 representa correctamente la correlación dinámica entre las variables.

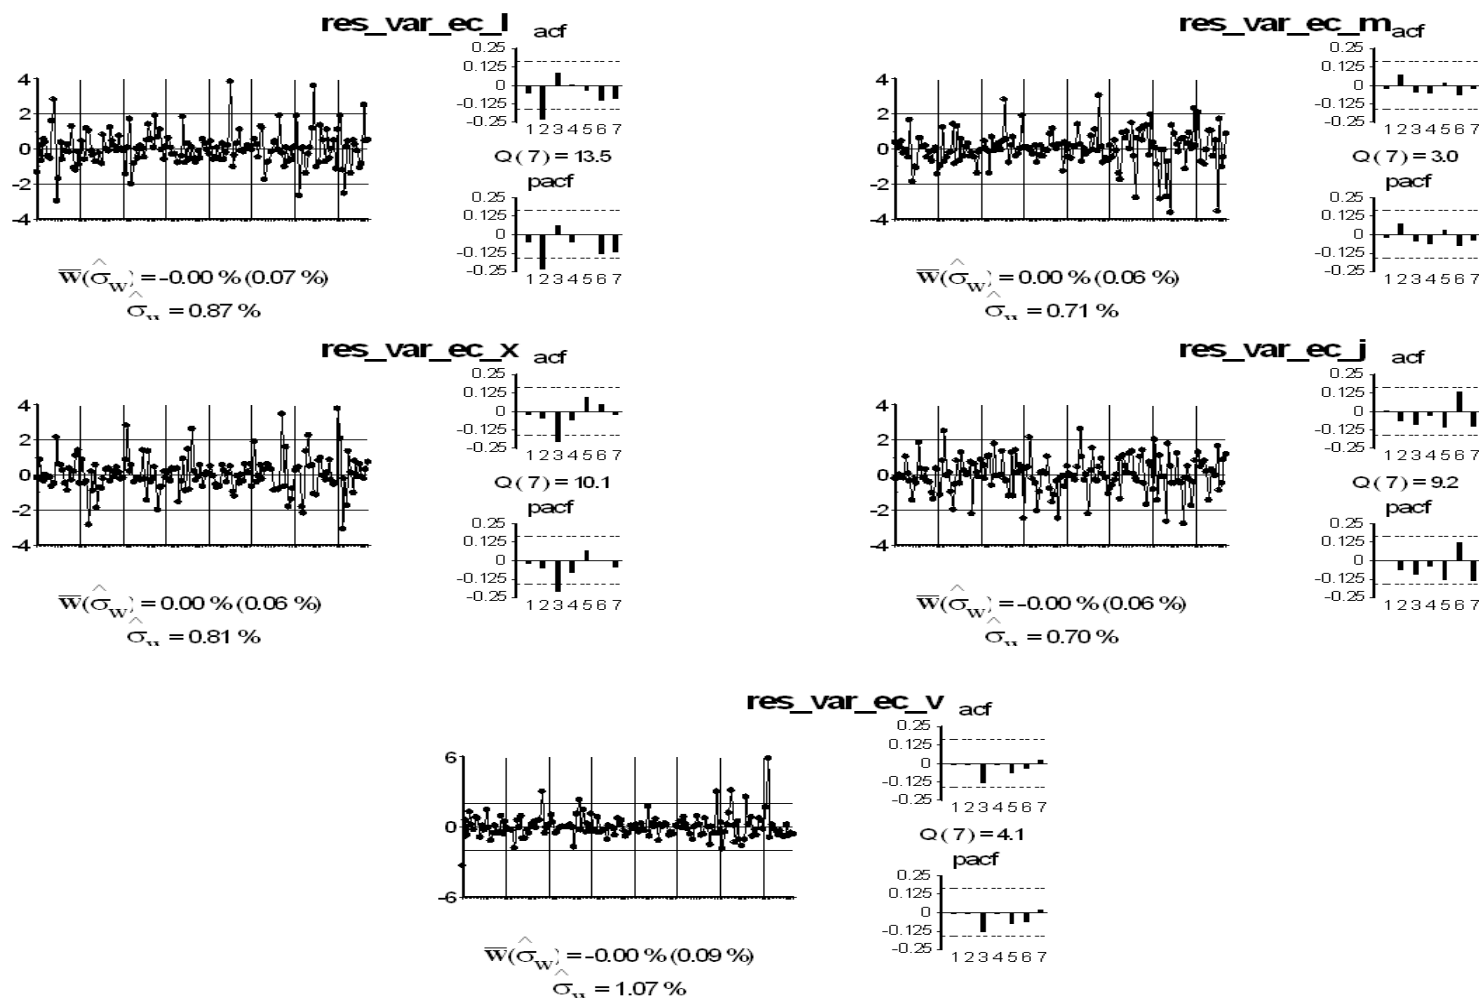


Gráfico 3.13: Banesto: Residuos del VAR(1)

Tabla 3.33: Banesto: Función de correlación cruzada residual del VAR(1)

Retardos	r_{11}	r_{12}	r_{13}	r_{14}	r_{15}
1	-0,051	0,018	0,003	0,002	0,015
2	-0,234*	-0,011	-0,061	0,032	-0,043
3	0,085	-0,043	-0,040	-0,058	0,029
4	0,003	0,031	0,105	-0,016	0,021
5	-0,039	0,029	-0,058	0,152	-0,021
	r_{21}	r_{22}	r_{23}	r_{24}	r_{25}
1	0,029	-0,023	0,007	0,010	0,019
2	-0,047	0,079	-0,064	0,078	-0,102
3	0,033	-0,049	-0,009	-0,092	-0,179*
4	0,086	-0,057	-0,013	0,091	-0,001
5	0,064	0,016	0,054	-0,064	0,121
	r_{31}	r_{32}	r_{33}	r_{34}	r_{35}
1	-0,082	0,022	-0,027	0,000	-0,010
2	-0,004	-0,042	-0,050	-0,146	-0,023
3	0,017	-0,129	-0,208*	-0,083	0,027
4	0,062	-0,045	-0,063	0,093	0,002
5	-0,004	-0,134	0,097	0,026	-0,090
	r_{41}	r_{42}	r_{43}	r_{44}	r_{45}
1	-0,012	0,022	-0,011	0,001	-0,025
2	0,012	0,040	0,122	-0,066	0,011
3	0,057	-0,043	-0,084	-0,094	0,181*
4	-0,032	0,041	0,047	-0,031	-0,143
5	-0,200*	-0,146	0,117	-0,115	0,109
	r_{51}	r_{52}	r_{53}	r_{54}	r_{55}
1	-0,017	0,047	0,006	0,021	-0,010
2	-0,001	-0,019	0,185*	0,032	-0,014
3	0,005	0,190*	-0,148*	-0,033	-0,135
4	0,205*	0,057	0,076	0,044	-0,008
5	0,091	0,071	-0,035	-0,025	-0,067

DT = $\frac{2}{\sqrt{T}} = 0,161$. En * significativos al 95 %.

3.B.10 Endesa

3.B.10.1 Elección orden del VAR

Los estadísticos de Akaike y de Schwarz aparecen en la tabla 3.34 para diversos ordenes del VAR. Ambos criterios sugieren que el modelo a estimar es un VAR(1)

Tabla 3.34: Endesa: Elección del orden del VAR

Retardos	1	2	3	4
AIC	-31,27	-31,06	-30,87	-30,78
SC	-30,68	-29,98	-29,29	-28,7

3.B.10.2 Estimación modelo VAR

Se estiman todos los parámetros de forma conjunta por mínimos cuadrados generalizados. Los resultados aparecen en la tabla 3.35.

Tabla 3.35: Endesa: Estimación del VAR(1) ortogonalizado

Variable dependiente	Ecuaciones ^a				
	l_t	m_t	x_t	j_t	v_t
μ	0,012 (0,009)	-0,013 (0,015)	-0,0023 (0,0088)	-0,0020 (0,0085)	-0,0035 (0,0082)
l_t		1,32 (0,13)	-0,30 (0,10)	0,20 (0,10)	0,19 (0,09)
m_t			1,16 (0,05)	-0,14 (0,10)	-0,070 (0,100)
x_t				1,06 (0,08)	-0,26 (0,11)
j_t					1,28 (0,08)
l_{t-1}	0,034 (0,053)	0,0037 (0,0832)	0,034 (0,049)	0,015 (0,047)	-0,0099 (0,0453)
m_{t-1}	0,031 (0,114)	-0,21 (0,18)	-0,029 (0,105)	-0,092 (0,101)	0,028 (0,098)
x_{t-1}	-0,020 (0,134)	0,11 (0,21)	-0,10 (0,12)	-0,0020 (0,1179)	-0,055 (0,114)
j_{t-1}	-0,19 (0,15)	-0,033 (0,243)	-0,052 (0,142)	0,099 (0,137)	-0,026 (0,132)
v_{t-1}	1,14 (0,10)	-0,19 (0,21)	0,20 (0,12)	-0,142 (0,119)	-0,071 (0,116)

^aLa tabla muestra los coeficientes estimados del modelo VAR donde cada columna representa una ecuación del mismo. Entre paréntesis se presentan las desviaciones típicas.

La matriz de covarianzas se presenta en (3.10).

$$\Sigma_u = \begin{pmatrix} 1,07E-04 & 1,41E-04 & 1,31E-04 & 1,41E-04 & 1,56E-04 \\ 1,41E-04 & 4,45E-04 & 4,74E-04 & 4,68E-04 & 4,71E-04 \\ 1,31E-04 & 4,74E-04 & 5,98E-04 & 5,95E-04 & 5,96E-04 \\ 1,41E-04 & 4,68E-04 & 5,95E-04 & 6,76E-04 & 7,03E-04 \\ 1,56E-04 & 4,71E-04 & 5,96E-04 & 7,03E-04 & 8,14E-04 \end{pmatrix} \quad (3.10)$$

En la tabla 3.36 se presentan las funciones de correlación cruzadas. Aunque una correlación es significativa, se considera que el modelo de la tabla 3.35 representa bien la relación entre las variables. El gráfico con los residuos del VAR(1) se muestra en 3.14.

Tabla 3.36: Endesa: Función de correlación cruzada residual - Modelo VAR(1)

Retardos	r_{11}	r_{12}	r_{13}	r_{14}	r_{15}
1	-0,032	0,004	0,009	0,010	0,011
2	0,037	0,039	-0,010	-0,039	-0,058
3	-0,144	0,006	0,034	0,010	-0,018
4	0,144	0,135	0,109	0,074	0,043
5	0,027	0,041	0,070	0,031	0,030
	r_{21}	r_{22}	r_{23}	r_{24}	r_{25}
1	-0,087	-0,020	-0,013	-0,007	-0,004
2	-0,055	-0,066	-0,116	-0,128	-0,153
3	-0,065	0,000	0,037	0,026	0,054
4	0,074	0,066	0,044	0,023	0,019
5	0,094	0,042	0,048	0,054	0,054
	r_{31}	r_{32}	r_{33}	r_{34}	r_{35}
1	-0,063	-0,011	-0,006	-0,001	0,000
2	-0,088	-0,087	-0,139	-0,141	-0,155
3	-0,056	0,009	0,043	0,041	0,059
4	0,026	0,029	0,015	-0,012	-0,007
5	0,116	0,014	0,013	0,022	0,025
	r_{41}	r_{42}	r_{43}	r_{44}	r_{45}
1	-0,076	-0,017	-0,011	-0,006	-0,003
2	-0,058	-0,054	-0,097	-0,109	-0,135
3	-0,143	-0,052	-0,018	-0,003	0,016
4	0,028	0,005	-0,004	-0,034	-0,030
5	0,080	-0,012	-0,002	-0,005	-0,009
	r_{51}	r_{52}	r_{53}	r_{54}	r_{55}
1	-0,074	-0,020	-0,013	-0,012	-0,008
2	-0,011	-0,012	-0,039	-0,042	-0,079
3	-0,218*	-0,093	-0,054	-0,045	-0,031
4	-0,002	-0,040	-0,056	-0,090	-0,095
5	0,090	0,030	0,038	0,034	0,016

DT = $\frac{2}{\sqrt{T}} = 0,161$. En * significativos al 95 %.

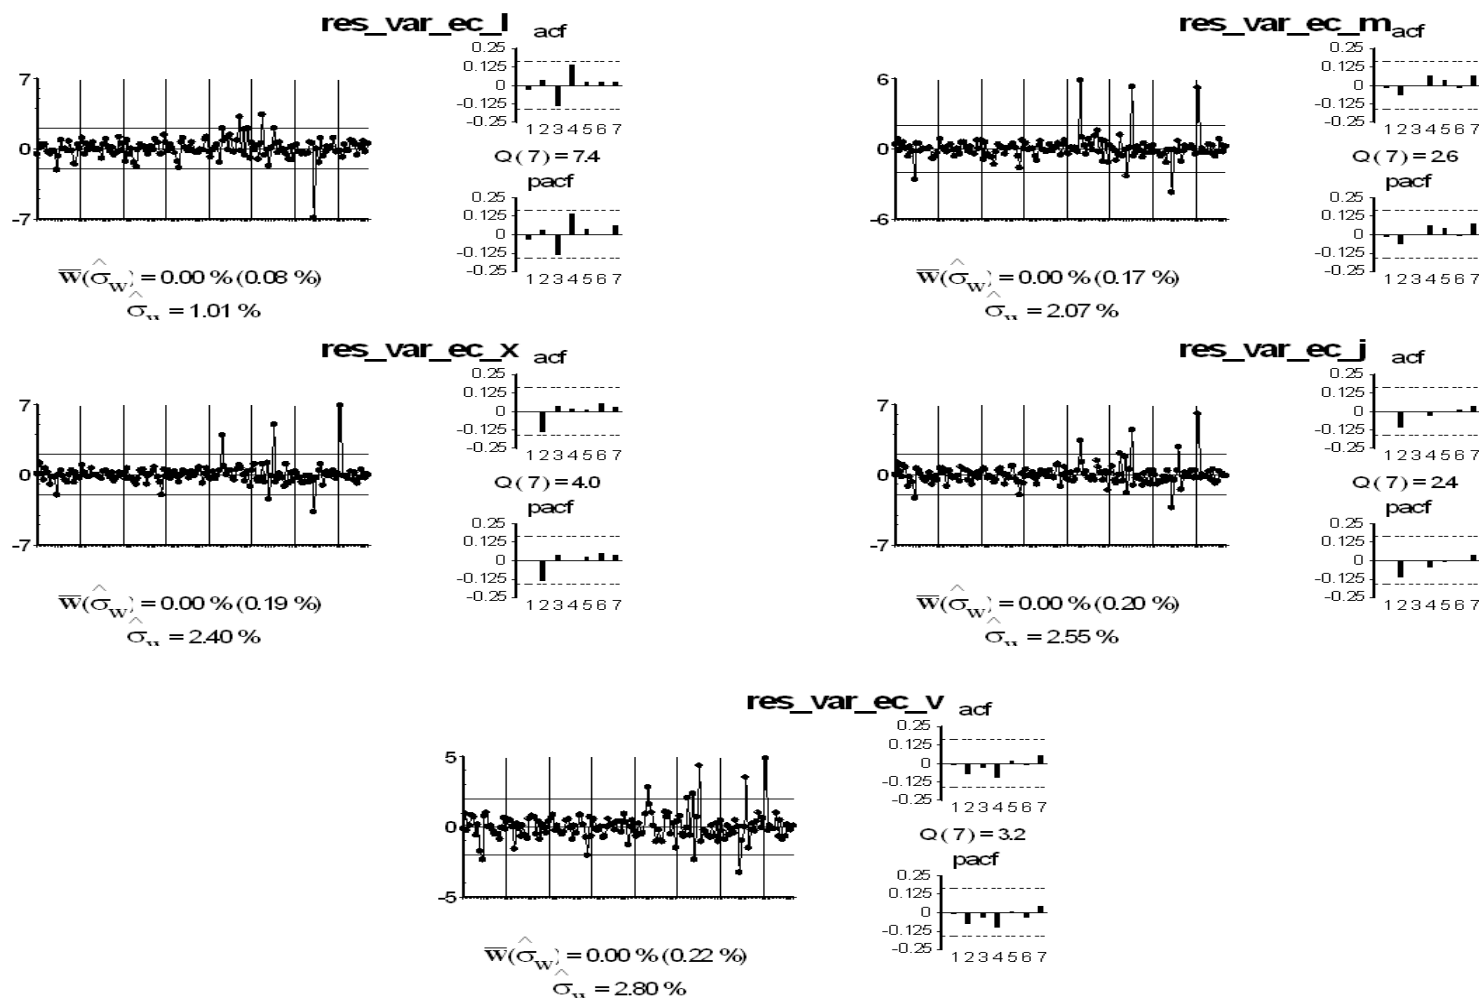


Gráfico 3.14: Endesa: Residuos del modelo

3.B.11 Enagas

3.B.11.1 Elección orden del VAR

En la tabla 3.37 se muestran los estadísticos de Akaike y de Schwarz para diversos ordenes del VAR.

Tabla 3.37: Enagas: Elección del orden del VAR

Retardos	1	2	3	4
AIC	-31,61	-31,56	-31,46	-31,32
SC	-31,03	-30,47	-29,88	-29,23

Ambos criterios sugieren que se debe estimar un VAR(1).

3.B.11.2 Estimación modelo VAR

Se estiman todos los parámetros de forma conjunta por mínimos cuadrados generalizados. Los resultados aparecen en la tabla 3.38.

Tabla 3.38: Enagas: Estimación del VAR(1) ortogonalizado

Variable dependiente	Ecuaciones ^a				
	l_t	m_t	x_t	j_t	v_t
μ	-0,0058 (0,0079)	0,0025 (0,015)	0,010 (0,008)	0,017 (0,010)	0,0032 (0,0079)
l_t		1,18 (0,07)	-0,43 (0,14)	-0,19 (0,17)	-0,32 (0,14)
m_t			1,25 (0,09)	-0,066 (0,168)	0,51 (0,13)
x_t				1,28 (0,10)	-0,48 (0,11)
j_t					1,17 (0,06)
l_{t-1}	0,10 (0,09)	0,11 (0,08)	-0,025 (0,093)	0,081 (0,113)	0,0083 (0,0902)
m_{t-1}	0,0018 (0,1344)	-0,088 (0,123)	0,0079 (0,1380)	-0,24 (0,17)	0,012 (0,134)
x_{t-1}	-0,067 (0,121)	-0,033 (0,111)	0,076 (0,124)	0,26 (0,15)	-0,059 (0,121)
j_{t-1}	-0,10 (0,12)	-0,068 (0,107)	-0,079 (0,120)	-0,24 (0,15)	0,14 (0,12)
v_{t-1}	1,07 (0,08)	-0,046 (0,111)	0,19 (0,12)	0,11 (0,15)	0,016 (0,121)

^aLa tabla muestra los coeficientes estimados del modelo VAR donde cada columna representa una ecuación del mismo. Entre paréntesis se presentan las desviaciones típicas.

La matriz de covarianzas se presenta en (3.11).

$$\Sigma_u = \begin{pmatrix} 9,69E-05 & 1,14E-04 & 1,01E-04 & 1,04E-04 & 1,01E-04 \\ 1,14E-04 & 2,15E-04 & 2,20E-04 & 2,47E-04 & 2,56E-04 \\ 1,01E-04 & 2,20E-04 & 3,33E-04 & 3,93E-04 & 3,80E-04 \\ 1,04E-04 & 2,47E-04 & 3,93E-04 & 6,15E-04 & 6,23E-04 \\ 1,01E-04 & 2,56E-04 & 3,80E-04 & 6,23E-04 & 7,36E-04 \end{pmatrix} \quad (3.11)$$

Los residuos del VAR(1) aparecen en el gráfico 3.15. En la tabla 3.39 aparecen las funciones de correlación cruzadas. Se aprecia que seis de ellas son significativas, aunque alguna de ellas aparece en retardos como el primero y el segundo, se decide elegir el modelo de la tabla 3.38 como aquel que representa correctamente la dinámica de las variables.

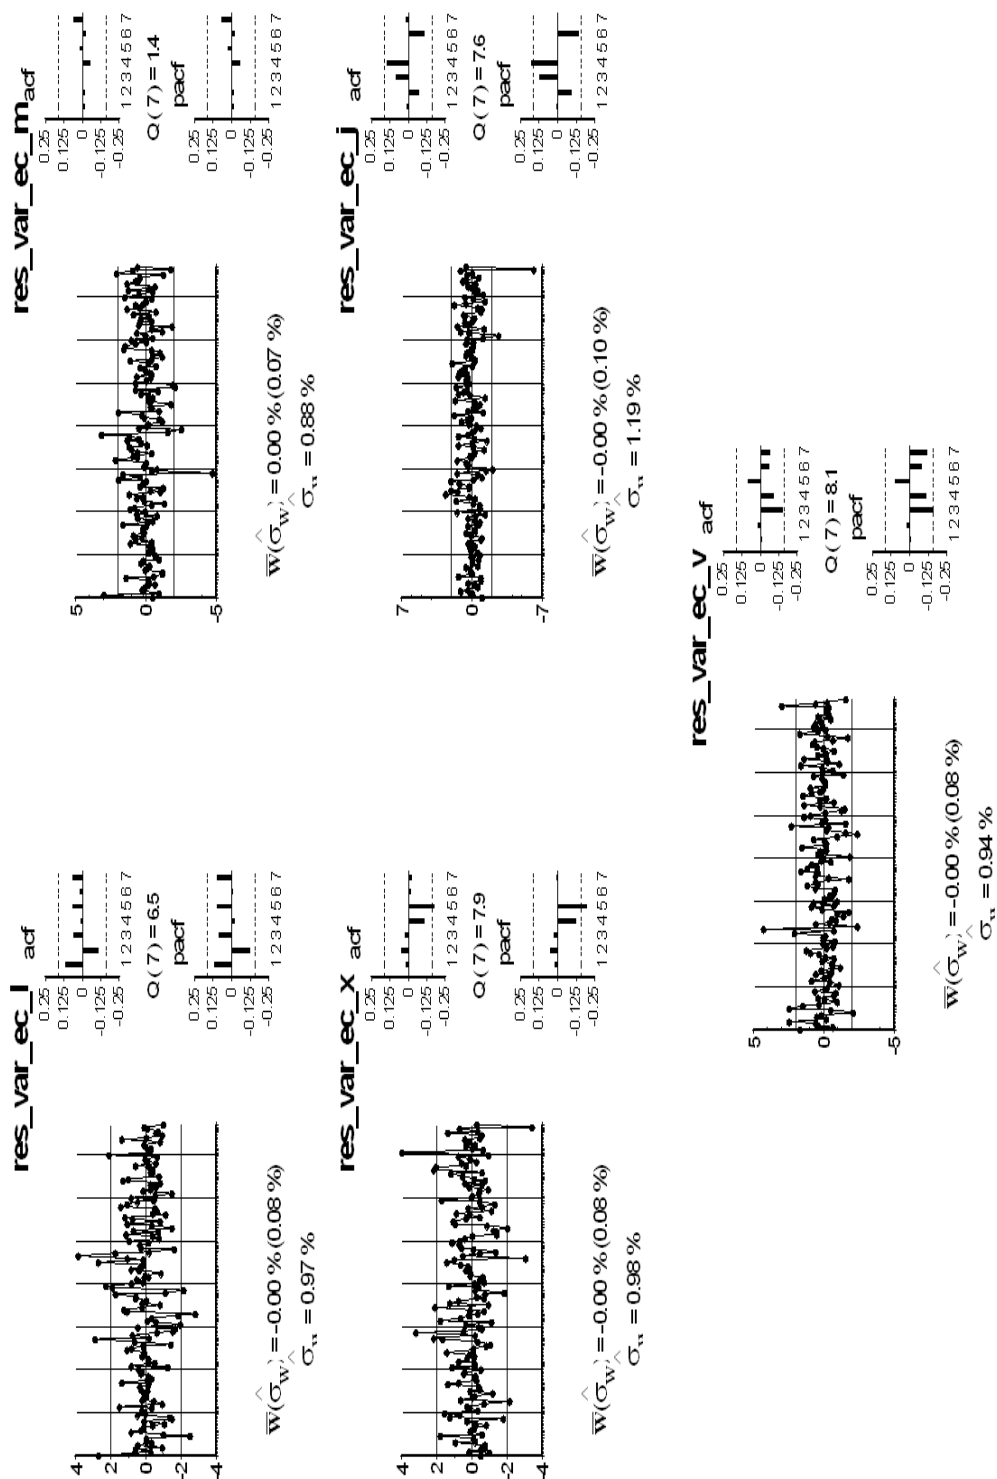


Gráfico 3.15: Enagas: Residuos del VAR(1)

Tabla 3.39: Enagas: Función de correlación cruzada residual del VAR(1)

Retardos	r_{11}	r_{12}	r_{13}	r_{14}	r_{15}
1	0,119	-0,037	0,034	0,048	0,013
2	-0,113	-0,118	-0,103	0,052	-0,050
3	0,059	0,020	-0,013	-0,016	-0,012
4	0,010	-0,014	0,001	0,034	0,038
5	0,072	-0,024	-0,082	0,068	0,013
	r_{21}	r_{22}	r_{23}	r_{24}	r_{25}
1	0,162*	-0,015	0,022	-0,015	0,013
2	0,038	-0,016	0,066	-0,003	-0,031
3	-0,052	-0,001	-0,163*	-0,017	0,035
4	-0,170*	-0,056	-0,015	0,044	-0,153
5	-0,136	0,021	0,022	-0,028	0,076
	r_{31}	r_{32}	r_{33}	r_{34}	r_{35}
1	0,105	-0,010	0,017	-0,011	0,003
2	-0,176*	0,044	0,050	0,009	-0,068
3	-0,052	0,054	0,029	0,005	0,010
4	0,034	0,026	-0,110	0,062	0,006
5	-0,040	0,026	-0,179*	0,092	-0,041
	r_{41}	r_{42}	r_{43}	r_{44}	r_{45}
1	-0,024	0,024	-0,006	0,010	-0,016
2	0,073	-0,077	-0,128	-0,073	-0,152
3	0,138	-0,009	-0,121	0,083	0,151
4	0,106	-0,185*	0,055	0,148	-0,014
5	-0,083	-0,218	0,003	-0,001	0,001
	r_{51}	r_{52}	r_{53}	r_{54}	r_{55}
1	-0,145	0,022	-0,019	0,029	-0,013
2	-0,067	0,041	-0,014	0,052	0,019
3	0,000	0,144	-0,052	0,031	-0,158
4	0,042	0,111	0,071	-0,057	-0,094
5	0,121	-0,022	0,010	-0,057	0,085

DT = $\frac{2}{\sqrt{T}} = 0,161$. En * significativos al 95 %.

3.B.12 FCC

3.B.12.1 Elección orden del VAR

Los estadísticos de Akaike y de Schwarz aparecen en la tabla 3.40 para diversos ordenes del VAR. Ambos no difieren en señalar que se debe estimar un VAR(1).

Tabla 3.40: FCC: Elección del orden del VAR

Retardos	1	2	3	4
AIC	-30,83	-30,66	-30,46	-30,36
SC	-30,24	-29,58	-28,88	-28,27

3.B.12.2 Estimación modelo VAR

Se estiman todos los parámetros de forma conjunta por mínimos cuadrados generalizados. Los resultados aparecen en la tabla 3.41.

Tabla 3.41: FCC: Estimación del VAR(1) ortogonalizado

Variable dependiente	Ecuaciones ^a				
	l_t	m_t	x_t	j_t	v_t
μ	-0,010 (0,011)	0,011 (0,009)	0,0041 (0,0105)	-0,0066 (0,0127)	0,0032 (0,0112)
l_t		1,17 (0,07)	0,028 (0,130)	0,14 (0,16)	-0,087 (0,139)
m_t			0,92 (0,09)	-0,27 (0,14)	0,20 (0,13)
x_t				1,23 (0,10)	-0,15 (0,12)
j_t					1,02 (0,07)
l_{t-1}	-0,22 (0,09)	0,031 (0,079)	-0,090 (0,087)	0,066 (0,106)	0,10 (0,09)
m_{t-1}	0,27 (0,13)	0,059 (0,108)	0,16 (0,12)	-0,24 (0,14)	-0,15 (0,13)
x_{t-1}	-0,10 (0,12)	-0,26 (0,10)	-0,18 (0,12)	0,36 (0,14)	0,044 (0,128)
j_{t-1}	-0,10 (0,11)	0,29 (0,09)	0,21 (0,11)	-0,079 (0,131)	-0,056 (0,115)
v_{t-1}	1,15 (0,08)	-0,29 (0,10)	-0,051 (0,119)	-0,21 (0,14)	0,064 (0,128)

^aLa tabla muestra los coeficientes estimados del modelo VAR donde cada columna representa una ecuación del mismo. Entre paréntesis se presentan las desviaciones típicas.

La matriz de covarianzas se presenta en (3.12).

$$\Sigma_u = \begin{pmatrix} 1,27E-04 & 1,49E-04 & 1,40E-04 & 1,51E-04 & 1,53E-04 \\ 1,49E-04 & 2,64E-04 & 2,47E-04 & 2,54E-04 & 2,64E-04 \\ 1,40E-04 & 2,47E-04 & 3,38E-04 & 3,70E-04 & 3,66E-04 \\ 1,51E-04 & 2,54E-04 & 3,70E-04 & 5,67E-04 & 5,63E-04 \\ 1,53E-04 & 2,64E-04 & 3,66E-04 & 5,63E-04 & 6,82E-04 \end{pmatrix} \quad (3.12)$$

Los residuos del VAR(1) aparecen en el gráfico 3.16. Por otro lado, en la tabla 3.42 se presentan las funciones de correlación cruzadas. Aunque diez de ellas son significativas, se considera que el modelo de la tabla 3.41 es el adecuado para representar la relación entre las variables.

Tabla 3.42: FCC: Función de correlación cruzada residual del VAR(1)

Retardos	r_{11}	r_{12}	r_{13}	r_{14}	r_{15}
1	-0,057	-0,051	-0,049	-0,035	-0,032
2	-0,188*	-0,169*	-0,126	-0,052	-0,073
3	0,001	0,021	0,054	0,057	0,076
4	0,017	0,029	0,021	0,056	0,097
5	0,080	0,155	0,172*	0,196*	0,207*
	r_{21}	r_{22}	r_{23}	r_{24}	r_{25}
1	-0,035	-0,038	-0,042	-0,041	-0,037
2	-0,189*	-0,172*	-0,092	-0,023	-0,090
3	-0,044	-0,024	0,005	0,031	0,047
4	0,018	0,014	0,001	0,069	0,079
5	0,028	0,129	0,140	0,177*	0,234*
	r_{31}	r_{32}	r_{33}	r_{34}	r_{35}
1	-0,080	-0,080	-0,084	-0,066	-0,058
2	-0,136	-0,124	-0,047	0,051	-0,023
3	-0,120	-0,100	-0,084	-0,051	-0,017
4	0,039	0,021	-0,036	-0,010	0,007
5	-0,016	0,038	0,072	0,127	0,163*
	r_{41}	r_{42}	r_{43}	r_{44}	r_{45}
1	-0,134	-0,118	-0,114	-0,086	-0,080
2	-0,096	-0,133	-0,064	0,044	-0,014
3	-0,036	-0,024	0,042	0,077	0,084
4	-0,037	-0,064	-0,120	-0,126	-0,081
5	-0,028	-0,007	0,035	0,102	0,115
	r_{51}	r_{52}	r_{53}	r_{54}	r_{55}
1	-0,106	-0,099	-0,095	-0,073	-0,072
2	-0,128	-0,200*	-0,118	0,004	-0,059
3	-0,050	-0,043	0,015	0,044	0,057
4	0,005	-0,039	-0,129	-0,151	-0,116
5	0,018	0,055	0,119	0,145	0,134

DT = $\frac{2}{\sqrt{T}} = 0,161$. En * significativos al 95 %.

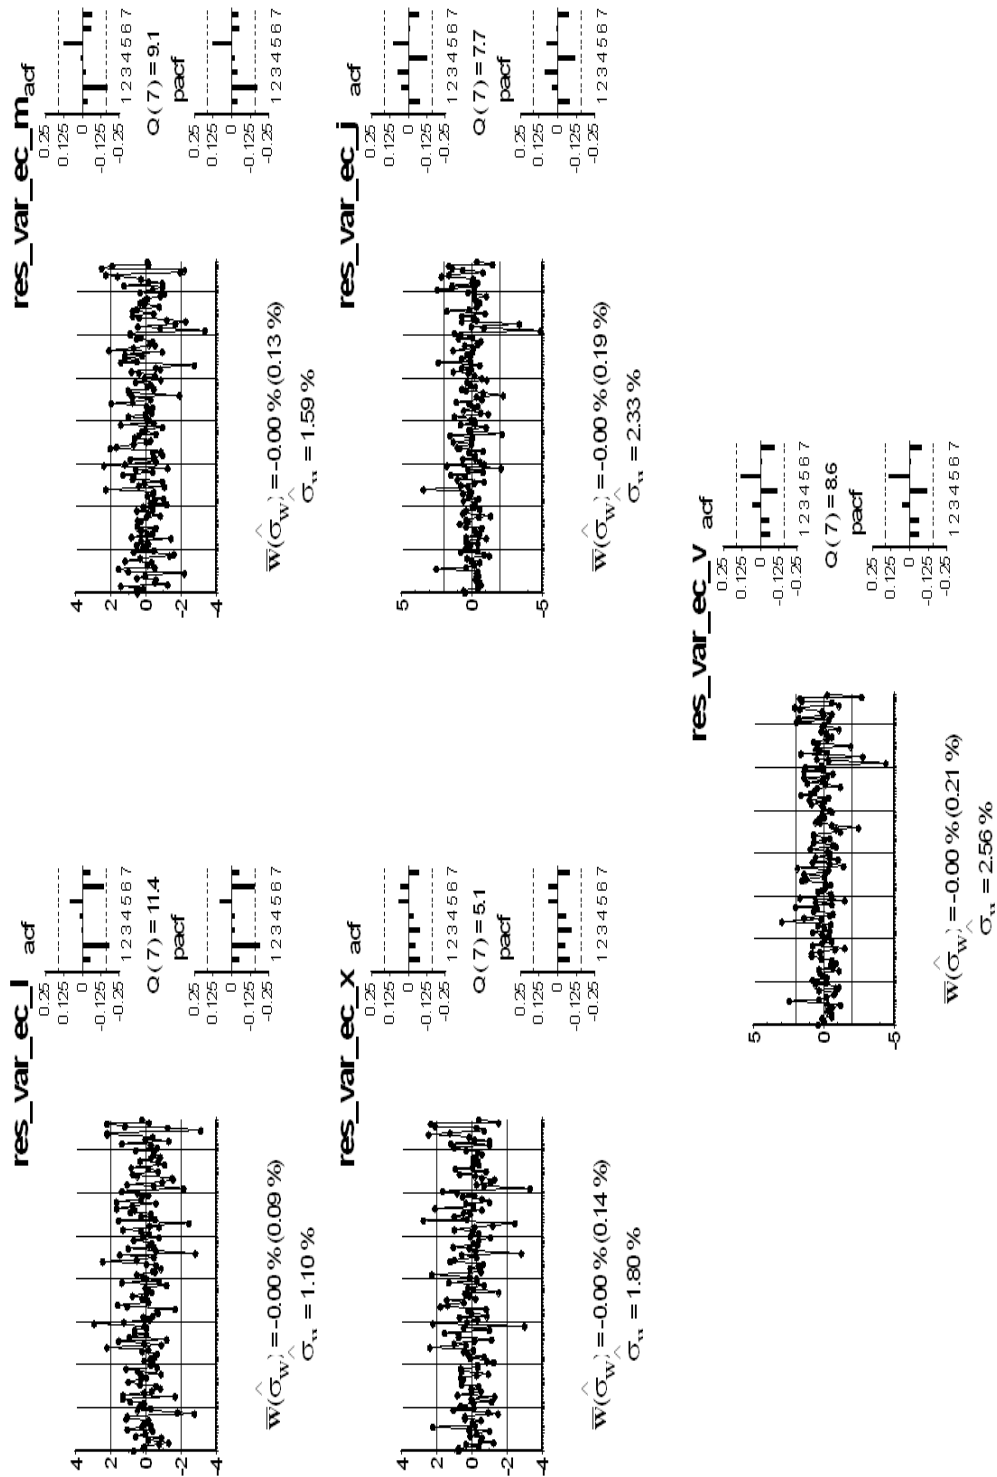


Gráfico 3.16: FCC: Residuos del VAR(1)

3.B.13 Ferrovial

3.B.13.1 Elección orden del VAR

En la tabla 3.43 se muestran los estadísticos de Akaike y de Schwarz para diversos ordenes del VAR.

Tabla 3.43: Ferrovial: Elección del orden del VAR

Retardos	1	2	3	4
AIC	-29,16	-29,04	-28,85	-28,67
SC	-28,57	-27,96	-27,27	-26,58

Ambos criterios coinciden en señalar que se debe estimar un VAR(1).

3.B.13.2 Estimación modelo VAR

Se estiman todos los parámetros de forma conjunta por mínimos cuadrados generalizados. Los resultados aparecen en la tabla 3.44.

Tabla 3.44: Ferrovial: Estimación del VAR(1) ortogonalizado

Variable dependiente	Ecuaciones ^a				
	l_t	m_t	x_t	j_t	v_t
μ	-0,0015 (0,014)	0,044 (0,015)	-0,0016 (0,0136)	-0,0063 (0,0159)	0,024 (0,015)
l_t		1,36 (0,07)	0,094 (0,124)	0,018 (0,146)	-0,22 (0,14)
m_t			0,91 (0,07)	-0,055 (0,122)	0,087 (0,116)
x_t				1,08 (0,10)	-0,28 (0,12)
j_t					1,24 (0,08)
l_{t-1}	-0,10 (0,07)	0,19 (0,07)	0,029 (0,068)	0,14 (0,08)	0,018 (0,08)
m_{t-1}	0,19 (0,11)	-0,17 (0,11)	-0,17 (0,10)	-0,14 (0,12)	0,049 (0,114)
x_{t-1}	-0,08 (0,121)	-0,24 (0,12)	0,049 (0,112)	0,070 (0,131)	-0,094 (0,124)
j_{t-1}	-0,12 (0,12)	0,34 (0,13)	0,0066 (0,1165)	-0,097 (0,136)	-0,15 (0,13)
v_{t-1}	1,11 (0,08)	-0,51 (0,12)	0,082 (0,117)	-0,026 (0,137)	0,34 (0,13)

^aLa tabla muestra los coeficientes estimados del modelo VAR donde cada columna representa una ecuación del mismo. Entre paréntesis se presentan las desviaciones típicas.

La matriz de covarianzas se presenta en (3.13).

$$\Sigma_u = \begin{pmatrix} 1,66E-04 & 2,26E-04 & 2,21E-04 & 2,30E-04 & 2,07E-04 \\ 2,26E-04 & 4,84E-04 & 4,62E-04 & 4,78E-04 & 4,57E-04 \\ 2,21E-04 & 4,62E-04 & 5,78E-04 & 6,06E-04 & 5,81E-04 \\ 2,30E-04 & 4,78E-04 & 6,06E-04 & 8,21E-04 & 8,39E-04 \\ 2,07E-04 & 4,57E-04 & 5,81E-04 & 8,39E-04 & 1,04E-03 \end{pmatrix} \quad (3.13)$$

Los residuos del VAR(1) aparecen en el gráfico 3.17. Por otro lado, en la tabla 3.45 se presentan los valores de la función de correlación cruzada, en ella se aprecia que dos de las correlaciones son estadísticamente distintas de 0. Aun así, se cree que el modelo de la tabla 3.44 representa de forma adecuada la correlación dinámica entre las variables.

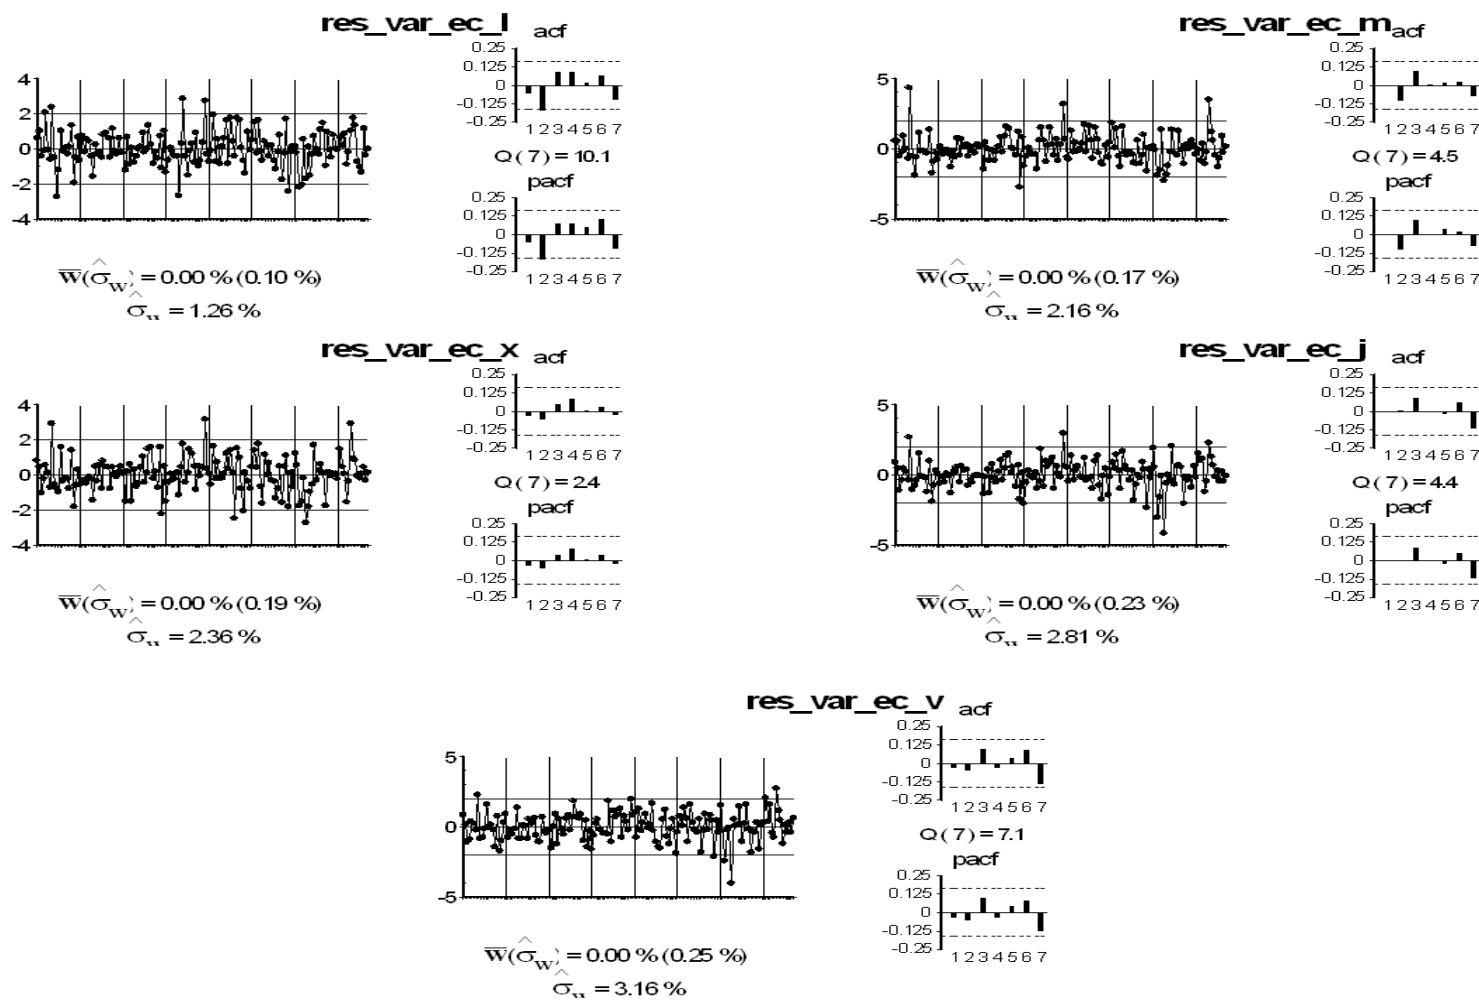


Gráfico 3.17: Ferrovial: Residuos del VAR(1)

Tabla 3.45: Ferrovial: Función de correlación cruzada residual del VAR(1)

Retardos	r_{11}	r_{12}	r_{13}	r_{14}	r_{15}
1	-0,055	-0,036	-0,030	-0,019	-0,022
2	-0,167*	-0,091	-0,122	-0,079	-0,055
3	0,091	0,048	0,021	0,002	-0,023
4	0,094	0,014	0,060	0,032	-0,018
5	0,017	0,001	-0,010	0,015	0,046
	r_{21}	r_{22}	r_{23}	r_{24}	r_{25}
1	-0,015	-0,006	-0,009	-0,003	-0,006
2	-0,181*	-0,104	-0,089	-0,059	-0,033
3	0,119	0,098	0,058	0,078	0,070
4	0,095	0,005	0,068	0,054	-0,001
5	0,048	0,019	0,009	0,051	0,127
	r_{31}	r_{32}	r_{33}	r_{34}	r_{35}
1	-0,052	-0,033	-0,034	-0,013	-0,014
2	-0,149	-0,035	-0,053	0,019	0,037
3	0,153	0,110	0,045	0,081	0,079
4	0,091	0,048	0,085	0,024	-0,026
5	0,011	-0,001	0,001	0,038	0,136
	r_{41}	r_{42}	r_{43}	r_{44}	r_{45}
1	-0,038	-0,023	-0,020	-0,005	-0,004
2	-0,099	-0,025	-0,040	0,001	-0,002
3	0,127	0,124	0,059	0,087	0,098
4	0,058	0,057	0,068	-0,005	-0,039
5	0,020	-0,024	-0,028	-0,021	0,057
	r_{51}	r_{52}	r_{53}	r_{54}	r_{55}
1	-0,085	-0,060	-0,052	-0,036	-0,029
2	-0,089	-0,057	-0,066	-0,022	-0,050
3	0,069	0,084	0,045	0,078	0,097
4	0,038	0,066	0,069	0,007	-0,033
5	-0,013	-0,042	-0,013	-0,013	0,037

DT= $\frac{2}{\sqrt{T}} = 0,161$. En * significativos al 95 %.

3.B.14 Gamesa

3.B.14.1 Elección orden del VAR

Los estadísticos de Akaike y de Schwarz para diversos ordenes del VAR aparecen en la tabla 3.46. Los dos criterios no difieren y por ello se decide estimar un VAR(1).

Tabla 3.46: Gamesa: Elección del orden del VAR

Retardos	1	2	3	4
AIC	-28,32	-28,16	-28,06	-28,05
SC	-27,73	-27,08	-26,48	-25,96

3.B.14.2 Estimación modelo VAR

Se estiman todos los parámetros de forma conjunta por mínimos cuadrados generalizados. Los resultados aparecen en la tabla 3.47.

Tabla 3.47: Gamesa: Estimación del VAR(1) ortogonalizado

Variable dependiente	Ecuaciones ^a				
	l_t	m_t	x_t	j_t	v_t
μ	0,0051 (0,0124)	0,016 (0,014)	-0,019 (0,015)	-0,0070 (0,0169)	0,023 (0,013)
l_t		1,24 (0,09)	-0,42 (0,15)	-0,16 (0,17)	0,074 (0,131)
m_t			1,16 (0,08)	0,21 (0,14)	0,033 (0,112)
x_t				0,97 (0,09)	-0,25 (0,09)
j_t					1,21 (0,06)
l_{t-1}	-0,050 (0,069)	0,032 (0,082)	-0,056 (0,085)	0,12 (0,09)	-0,056 (0,075)
m_{t-1}	0,074 (0,101)	-0,057 (0,118)	-0,041 (0,123)	-0,17 (0,14)	0,081 (0,108)
x_{t-1}	-0,028 (0,089)	0,033 (0,104)	0,20 (0,11)	0,0083 (0,1214)	-0,052 (0,096)
j_{t-1}	-0,090 (0,111)	0,0051 (0,1299)	-0,095 (0,136)	-0,075 (0,150)	-0,043 (0,12)
v_{t-1}	1,09 (0,08)	-0,26 (0,14)	0,27 (0,15)	0,10 (0,16)	-0,0061 (0,1290)

^aLa tabla muestra los coeficientes estimados del modelo VAR donde cada columna representa una ecuación del mismo. Entre paréntesis se presentan las desviaciones típicas.

La matriz de covarianzas se presenta en (3.14).

$$\Sigma_u = \begin{pmatrix} 1,48E-04 & 1,84E-04 & 1,50E-04 & 1,61E-04 & 1,75E-04 \\ 1,84E-04 & 4,31E-04 & 4,21E-04 & 4,71E-04 & 4,92E-04 \\ 1,50E-04 & 4,21E-04 & 6,43E-04 & 6,90E-04 & 6,99E-04 \\ 1,61E-04 & 4,71E-04 & 6,90E-04 & 1,01E-03 & 1,08E-03 \\ 1,75E-04 & 4,92E-04 & 6,99E-04 & 1,08E-03 & 1,32E-03 \end{pmatrix} \quad (3.14)$$

Los residuos del VAR(1) aparecen en el gráfico 3.18. Por otro lado, en la tabla 3.48 se presentan las funciones de correlación cruzadas. Dos de ellas presentan correlaciones significativas, sin embargo, se considera que el modelo de la tabla 3.47 es apropiado para representar la relación entre las variables.

Tabla 3.48: Gamesa: Función de correlación cruzada residual del VAR(1)

Retardos	r_{11}	r_{12}	r_{13}	r_{14}	r_{15}
1	0,017	0,010	0,010	-0,001	-0,006
2	-0,022	0,040	0,020	-0,006	0,044
3	-0,06	-0,012	0,050	0,094	0,090
4	-0,165*	-0,183*	-0,128	-0,081	-0,093
5	0,144	0,058	-0,053	-0,089	-0,089
	r_{21}	r_{22}	r_{23}	r_{24}	r_{25}
1	-0,078	-0,046	-0,046	-0,037	-0,037
2	-0,072	0,016	0,064	0,024	0,070
3	0,044	0,088	0,062	0,100	0,079
4	-0,094	-0,117	-0,090	-0,056	-0,102
5	0,046	-0,001	-0,064	-0,096	-0,109
	r_{31}	r_{32}	r_{33}	r_{34}	r_{35}
1	-0,095	-0,055	-0,058	-0,032	-0,029
2	-0,103	0,011	0,057	0,015	0,043
3	-0,019	0,033	0,020	0,015	-0,034
4	-0,104	-0,107	-0,040	-0,060	-0,078
5	0,027	-0,010	-0,079	-0,074	-0,071
	r_{41}	r_{42}	r_{43}	r_{44}	r_{45}
1	-0,058	-0,034	-0,042	-0,019	-0,019
2	-0,062	0,012	0,058	-0,010	0,028
3	-0,009	0,083	0,023	0,020	-0,013
4	-0,082	-0,081	-0,070	-0,049	-0,054
5	-0,044	-0,104	-0,132	-0,127	-0,088
	r_{51}	r_{52}	r_{53}	r_{54}	r_{55}
1	-0,052	-0,030	-0,034	-0,012	-0,014
2	-0,010	0,038	0,050	-0,005	0,038
3	-0,032	0,106	0,058	0,067	0,035
4	-0,059	-0,036	-0,073	-0,064	-0,089
5	-0,031	-0,090	-0,113	-0,120	-0,070

DT = $\frac{2}{\sqrt{T}} = 0,161$. En * significativos al 95 %.

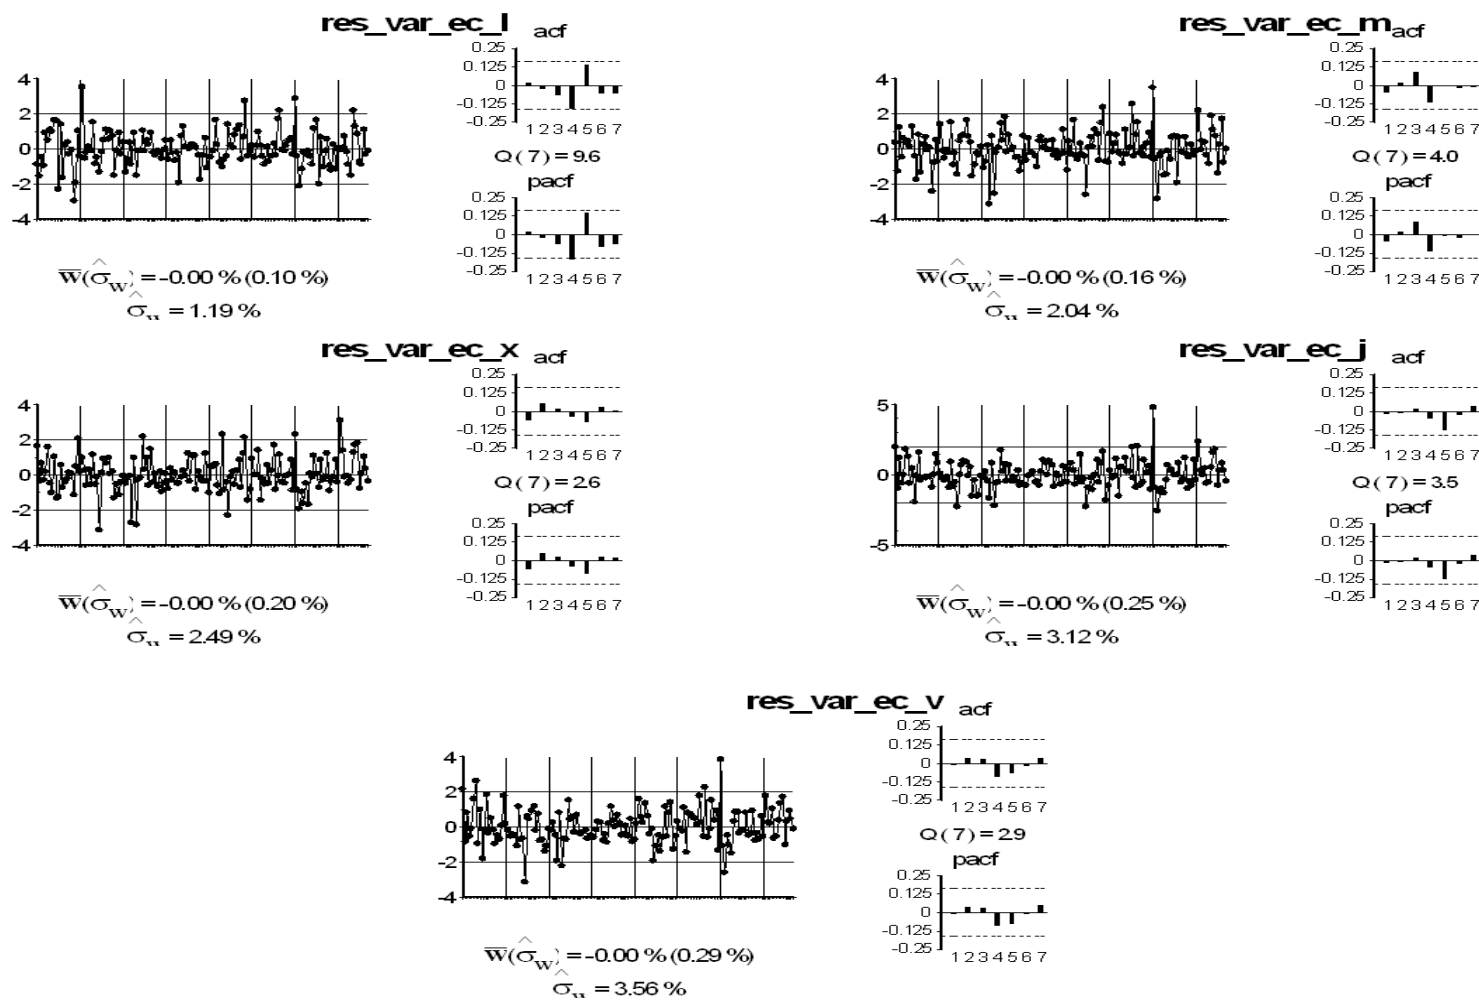


Gráfico 3.18: Gamesa: Residuos del VAR(1)

3.B.15 Gas Natural

3.B.15.1 Elección orden del VAR

En la tabla 3.49 se muestran los estadísticos de Akaike y de Schwarz para diversos ordenes del VAR.

Tabla 3.49: Gas Natural: Elección del orden del VAR

Retardos	1	2	3	4
AIC	-32,46	-32,39	-32,34	-32,20
SC	-31,87	-31,3	-30,75	-30,11

Los dos criterios no difieren y por ello se decide estimar un VAR(1).

3.B.15.2 Estimación modelo VAR

Se estiman todos los parámetros de forma conjunta por mínimos cuadrados generalizados. Los resultados aparecen en la tabla 3.50.

Tabla 3.50: Gas Natural: Estimación del VAR(1) ortogonalizado

Variable dependiente	Ecuaciones ^a				
	l_t	m_t	x_t	j_t	v_t
l_t		1,25 (0,09)	-0,54 (0,18)	-0,0060 (0,1650)	-0,18 (0,12)
m_t			1,22 (0,11)	0,15 (0,13)	0,19 (0,10)
x_t				0,86 (0,08)	-0,48 (0,08)
j_t					1,35 (0,06)
l_{t-1}	-0,13 (0,07)	0,10 (0,08)	0,23 (0,11)	-0,036 (0,098)	0,018 (0,074)
m_{t-1}	0,15 (0,10)	-0,084 (0,105)	-0,23 (0,14)	-0,11 (0,12)	-0,053 (0,095)
x_{t-1}	0,026 (0,085)	-0,16 (0,09)	0,0014 (0,1253)	0,27 (0,11)	0,040 (0,084)
j_{t-1}	-0,21 (0,13)	0,26 (0,14)	0,27 (0,20)	-0,24 (0,17)	0,056 (0,131)
v_{t-1}	1,18 (0,08)	-0,37 (0,14)	0,048 (0,193)	0,10 (0,17)	0,039 (0,126)

^aLa tabla muestra los coeficientes estimados del modelo VAR donde cada columna representa una ecuación del mismo. Entre paréntesis se presentan las desviaciones típicas.

La matriz de covarianzas se presenta en (3.15).

$$\Sigma_u = \begin{pmatrix} 6,69E-05 & 8,38E-05 & 6,58E-05 & 6,92E-05 & 6,66E-05 \\ 8,38E-05 & 1,81E-04 & 1,75E-04 & 1,78E-04 & 1,78E-04 \\ 6,58E-05 & 1,75E-04 & 3,19E-04 & 3,01E-04 & 2,77E-04 \\ 6,92E-05 & 1,78E-04 & 3,01E-04 & 3,93E-04 & 4,09E-04 \\ 6,66E-05 & 1,78E-04 & 2,77E-04 & 4,09E-04 & 5,04E-04 \end{pmatrix} \quad (3.15)$$

Los residuos del VAR(1) se muestran en el gráfico 3.19. Por otro lado, en la tabla 3.51 se presentan las funciones de correlación cruzadas. Aunque ocho de las correlaciones de la tabla son significativas, se considera que el modelo de la tabla 3.50 representa de forma adecuada la correlación dinámica entre las variables.

Tabla 3.51: Gas Natural: Función de correlación cruzada residual del VAR(1)

Retardos	r_{11}	r_{12}	r_{13}	r_{14}	r_{15}
1	0,005	-0,013	-0,046	-0,026	-0,021
2	-0,051	-0,056	-0,060	-0,061	-0,122
3	-0,067	0,011	0,177*	0,088	0,043
4	0,116	0,161*	0,197*	0,163*	0,112
5	0,087	0,106	0,152	0,091	0,031
	r_{21}	r_{22}	r_{23}	r_{24}	r_{25}
1	-0,032	-0,026	-0,047	-0,028	-0,021
2	-0,012	-0,023	-0,053	-0,073	-0,126
3	-0,046	-0,007	0,088	0,094	0,074
4	0,136	0,194*	0,233*	0,295*	0,185*
5	-0,061	-0,040	0,067	0,040	0,031
	r_{31}	r_{32}	r_{33}	r_{34}	r_{35}
1	-0,024	0,002	0,015	-0,001	-0,008
2	0,004	0,079	0,090	0,015	-0,001
3	0,061	0,001	0,044	0,044	0,021
4	0,032	0,053	0,144	0,130	0,121
5	-0,127	-0,081	0,019	-0,006	0,013
	r_{41}	r_{42}	r_{43}	r_{44}	r_{45}
1	-0,034	-0,004	-0,011	-0,018	-0,020
2	-0,047	-0,011	0,011	-0,075	-0,109
3	0,059	-0,001	0,064	0,067	0,046
4	-0,006	0,042	0,108	0,106	0,118
5	-0,084	-0,036	0,015	0,003	0,034
	r_{51}	r_{52}	r_{53}	r_{54}	r_{55}
1	-0,067	-0,033	-0,051	-0,047	-0,044
2	0,010	-0,025	-0,023	-0,092	-0,142
3	0,009	-0,052	0,031	0,033	-0,010
4	-0,054	-0,022	0,042	0,058	0,083
5	-0,107	-0,017	0,053	0,053	0,095

DT = $\frac{2}{\sqrt{T}} = 0,161$. En * significativos al 95 %.

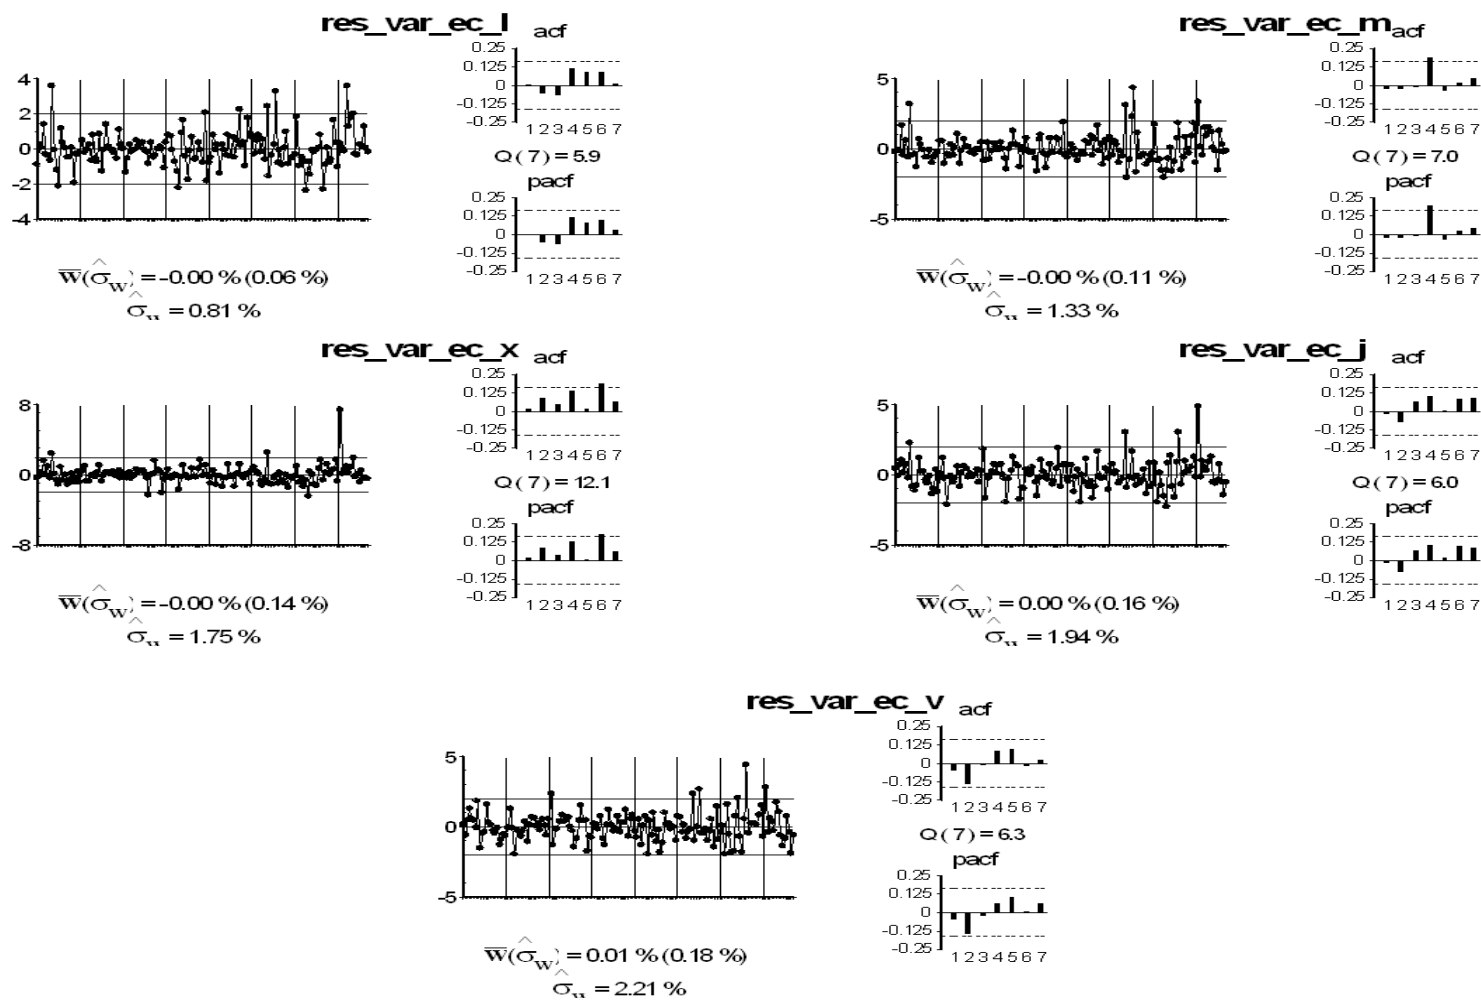


Gráfico 3.19: Gas Natural: Residuos del VAR(1)

3.B.16 Iberdrola

3.B.16.1 Elección orden del VAR

En la tabla 3.52 se muestran los estadísticos de Akaike y de Schwarz para diversos ordenes del VAR. Los dos criterios difieren, mientras que el de Akaike indica que se debe estimar un VAR(3), Schwarz se inclina por un VAR(1). Se comienza estimando un VAR(1) con constante, y se deja que sea la función de correlación cruzada la que indique si es necesario incrementar el orden del VAR.

Tabla 3.52: Iberdrola: Elección del orden del VAR

Retardos	1	2	3	4
AIC	-32,22	-32,42	-32,43	-32,30
SC	-31,63	-31,37	-30,85	-30,21

3.B.16.2 Estimación modelo VAR

Se estiman todos los parámetros de forma conjunta por mínimos cuadrados generalizados. Los resultados aparecen en la tabla 3.53.

Tabla 3.53: Iberdrola: Estimación del VAR(1) ortogonalizado

Variable dependiente	Ecuaciones ^a				
	l_t	m_t	x_t	j_t	v_t
μ	0,0099 (0,0049)	0,0013 (0,0058)	-0,011 (0,015)	0,0047 (0,0051)	-0,0031 (0,0056)
l_t		1,26 (0,09)	-0,28 (0,20)	-0,034 (0,124)	-0,058 (0,135)
m_t			1,25 (0,12)	-0,070 (0,096)	0,38 (0,10)
x_t				0,99 (0,05)	-0,67 (0,10)
j_t					1,45 (0,09)
l_{t-1}	-0,0049 (0,0701)	0,19 (0,08)	0,12 (0,12)	-0,061 (0,073)	0,050 (0,080)
m_{t-1}	0,044 (0,097)	-0,30 (0,11)	-0,11 (0,16)	0,083 (0,102)	-0,093 (0,111)
x_{t-1}	-0,026 (0,104)	0,23 (0,12)	0,0063 (0,1755)	0,081 (0,108)	0,060 (0,118)
j_{t-1}	-0,081 (0,132)	-0,17 (0,15)	-0,0011 (0,2210)	-0,19 (0,14)	-0,060 (0,149)
v_{t-1}	1,06 (0,07)	-0,21 (0,13)	0,022 (0,191)	0,20 (0,12)	-0,058 (0,130)

^aLa tabla muestra los coeficientes estimados del modelo VAR donde cada columna representa una ecuación del mismo. Entre paréntesis se presentan las desviaciones típicas.

La matriz de covarianzas se presenta en (3.16).

$$\Sigma_u = \begin{pmatrix} 6,62E-05 & 8,32E-05 & 8,57E-05 & 7,70E-05 & 8,22E-05 \\ 8,32E-05 & 1,94E-04 & 2,20E-04 & 2,02E-04 & 2,15E-04 \\ 8,57E-05 & 2,20E-04 & 4,31E-04 & 4,10E-04 & 3,84E-04 \\ 7,70E-05 & 2,02E-04 & 4,10E-04 & 4,59E-04 & 4,63E-04 \\ 8,22E-05 & 2,15E-04 & 3,84E-04 & 4,63E-04 & 5,71E-04 \end{pmatrix} \quad (3.16)$$

Los residuos del VAR(1) aparecen en el gráfico 3.20. Por otro lado, en la tabla 3.54 se presentan las funciones de correlación cruzadas. Diez de ellas son significativas, pero de momento se considera el modelo 3.53 lo suficientemente adecuado para representar la correlación dinámica entre las variables, y no se estima un VAR(3) como sugiere el criterio de Akaike.

Tabla 3.54: Iberdrola: Función de correlación cruzada residual del VAR(1)

Retardos	r_{11}	r_{12}	r_{13}	r_{14}	r_{15}
1	-0,094	0,003	-0,013	-0,012	0,002
2	-0,013	-0,087	-0,020	0,022	0,115
3	0,095	0,194*	-0,125	0,004	-0,105
4	0,057	0,021	0,126	0,023	-0,008
5	-0,088	-0,086	0,114	-0,048	0,073
	r_{21}	r_{22}	r_{23}	r_{24}	r_{25}
1	-0,035	0,003	-0,008	0,008	-0,007
2	0,153	-0,115	-0,070	0,094	0,087
3	-0,146	0,070	0,040	0,110	0,024
4	-0,080	0,075	0,030	0,093	-0,110
5	-0,007	-0,084	-0,015	0,129	-0,019
	r_{31}	r_{32}	r_{33}	r_{34}	r_{35}
1	-0,222*	0,093	0,018	-0,056	0,014
2	-0,207*	0,228*	-0,085	0,247*	0,356*
3	0,164*	0,059	-0,097	-0,182*	0,028
4	-0,041	0,024	-0,090	-0,053	-0,163*
5	-0,038	-0,033	-0,010	0,002	0,062
	r_{41}	r_{42}	r_{43}	r_{44}	r_{45}
1	0,044	0,014	-0,005	0,027	0,013
2	-0,102	-0,024	-0,082	0,030	-0,273*
3	-0,046	-0,005	0,033	-0,044	-0,020
4	-0,116	-0,094	0,010	0,035	-0,117
5	0,001	0,027	0,056	-0,065	0,085
	r_{51}	r_{52}	r_{53}	r_{54}	r_{55}
1	0,026	0,018	0,011	0,002	0,005
2	0,040	0,115	0,018	0,039	-0,061
3	-0,098	0,157	0,060	-0,114	-0,048
4	0,071	0,048	-0,078	0,008	-0,123
5	-0,093	-0,067	-0,031	0,131	0,048

DT = $\frac{2}{\sqrt{T}} = 0,161$. En * significativos al 95 %.

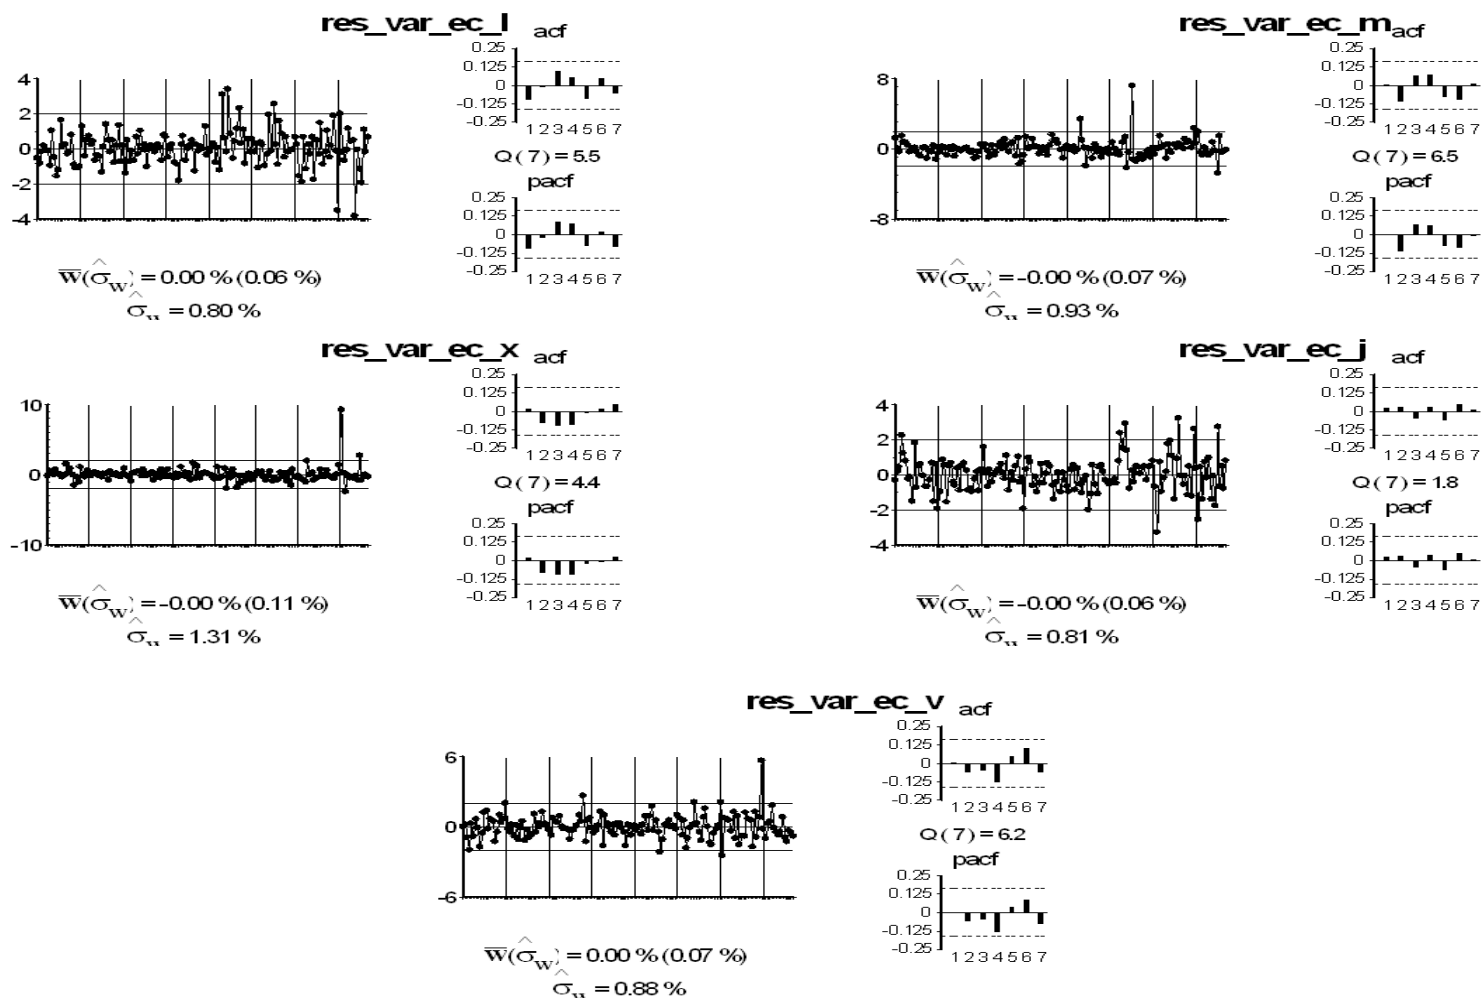


Gráfico 3.20: Iberdrola: Residuos del VAR(1)

3.B.17 Iberia

3.B.17.1 Elección orden del VAR

En la tabla 3.55 se muestran los estadísticos de Akaike y de Schwarz para diversos ordenes del VAR.

Tabla 3.55: Iberia: Elección del orden del VAR

Retardos	1	2	3	4
AIC	-28,65	-28,69	-28,56	-28,37
SC	-28,06	-27,61	-26,97	-26,28

Los dos criterios no coinciden al indicar el orden del VAR a estimar. Por un lado, el criterio de Akaike indica que se debe estimar un VAR(2), mientras que el criterio de Schwarz se inclina por un VAR(1). Se empieza estimando un VAR(1) y se deja que sea la función de correlación cruzada la que indique si es necesario incrementar el orden del VAR.

3.B.17.2 Estimación modelo VAR

Se estiman todos los parámetros de forma conjunta por mínimos cuadrados generalizados. Los resultados aparecen en la tabla 3.56.

Tabla 3.56: Iberia: Estimación del VAR(1) ortogonalizado

Variable dependiente	Ecuaciones ^a				
	l_t	m_t	x_t	j_t	v_t
l_t		1,11 (0,10)	-0,37 (0,18)	0,015 (0,131)	0,016 (0,150)
m_t			1,17 (0,11)	-0,095 (0,105)	0,064 (0,122)
x_t				1,05 (0,06)	-0,26 (0,12)
j_t					1,12 (0,09)
l_{t-1}	0,016 (0,067)	0,024 (0,079)	-0,21 (0,10)	-0,17 (0,08)	-0,052 (0,090)
m_{t-1}	-0,017 (0,087)	0,029 (0,104)	0,077 (0,139)	0,10 (0,10)	0,015 (0,116)
x_{t-1}	0,11 (0,09)	-0,21 (0,11)	0,16 (0,15)	-0,011 (0,108)	-0,070 (0,124)
j_{t-1}	-0,30 (0,10)	0,37 (0,12)	-0,23 (0,17)	-0,015 (0,122)	0,015 (0,140)
v_{t-1}	1,19 (0,06)	-0,33 (0,14)	0,37 (0,19)	0,12 (0,14)	0,14 (0,16)

^aLa tabla muestra los coeficientes estimados del modelo VAR donde cada columna representa una ecuación del mismo. Entre paréntesis se presentan las desviaciones típicas.

La matriz de covarianzas se presenta en (3.17).

$$\Sigma_u = \begin{pmatrix} 1,22E-04 & 1,36E-04 & 1,14E-04 & 1,08E-04 & 1,02E-04 \\ 1,36E-04 & 3,22E-04 & 3,26E-04 & 3,13E-04 & 2,88E-04 \\ 1,14E-04 & 3,26E-04 & 6,42E-04 & 6,43E-04 & 5,75E-04 \\ 1,08E-04 & 3,13E-04 & 6,43E-04 & 8,02E-04 & 7,52E-04 \\ 1,02E-04 & 2,88E-04 & 5,75E-04 & 7,52E-04 & 9,18E-04 \end{pmatrix} \quad (3.17)$$

El gráfico 3.21 muestra los residuos del VAR(1). Por otro lado, en la tabla 3.57 se presentan las funciones de correlación cruzadas. En ninguna de ellas se aprecian correlaciones significativas, por lo cual estos resultados sugieren que el modelo de la tabla 3.56 representa de forma adecuada la correlación dinámica entre las variables. Por lo tanto no es necesario incrementar el orden del VAR como indica el criterio de Akaike.

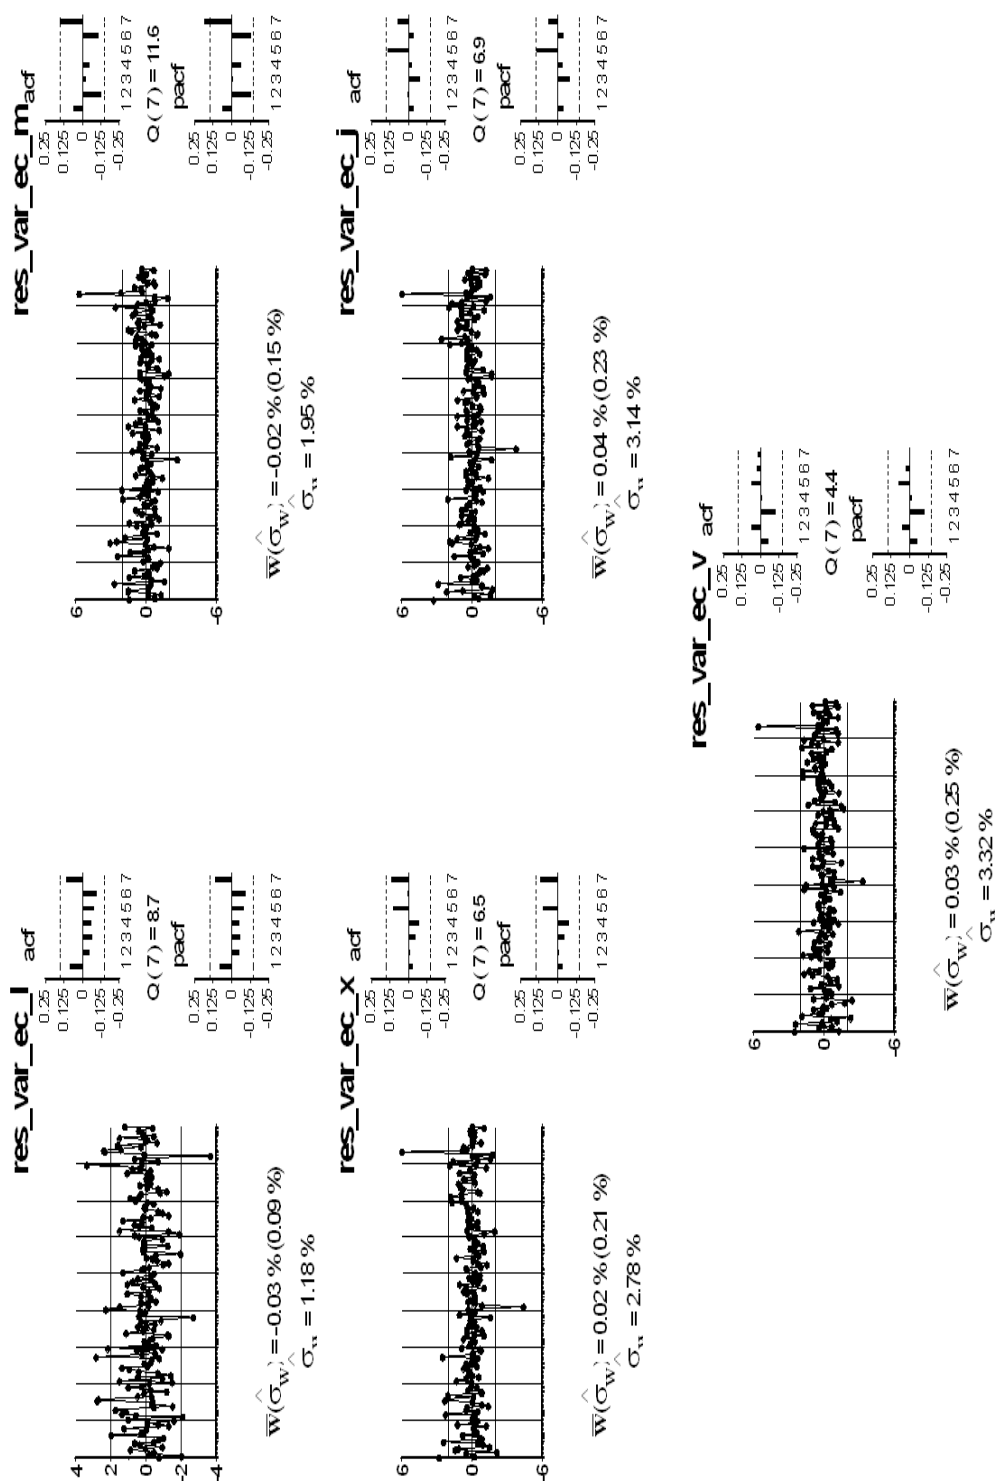


Gráfico 3.21: Iberia: Residuos del VAR(1)

Tabla 3.57: Iberia: Función de correlación cruzada residual del VAR(1)

Retardos	r_{11}	r_{12}	r_{13}	r_{14}	r_{15}
1	0,081	0,064	0,047	0,043	0,040
2	-0,045	-0,049	-0,062	-0,062	0,002
3	-0,070	-0,004	0,004	0,042	0,051
4	-0,062	-0,023	-0,001	0,017	0,019
5	-0,086	-0,152	-0,078	-0,100	-0,099
	r_{21}	r_{22}	r_{23}	r_{24}	r_{25}
1	0,116	0,061	0,029	0,025	0,016
2	-0,159	-0,128	-0,089	-0,046	0,015
3	-0,061	-0,026	-0,039	-0,038	-0,031
4	-0,100	-0,048	-0,005	0,059	0,046
5	-0,044	-0,007	0,074	0,072	0,023
	r_{31}	r_{32}	r_{33}	r_{34}	r_{35}
1	0,031	-0,018	-0,029	-0,024	-0,030
2	-0,110	-0,078	-0,008	0,029	0,007
3	-0,094	-0,034	-0,048	-0,071	-0,069
4	-0,120	-0,098	-0,074	-0,031	-0,015
5	-0,043	0,024	0,103	0,110	0,061
	r_{41}	r_{42}	r_{43}	r_{44}	r_{45}
1	-0,006	-0,045	-0,050	-0,038	-0,044
2	-0,122	-0,130	-0,037	0,006	-0,005
3	-0,099	-0,066	-0,066	-0,081	-0,085
4	-0,106	-0,064	-0,062	-0,026	-0,004
5	-0,050	0,030	0,116	0,142	0,103
	r_{51}	r_{52}	r_{53}	r_{54}	r_{55}
1	-0,049	-0,063	-0,057	-0,051	-0,056
2	-0,091	-0,081	0,043	0,089	0,058
3	-0,121	-0,078	-0,064	-0,074	-0,108
4	-0,128	-0,070	-0,061	-0,023	-0,008
5	-0,080	-0,010	0,103	0,125	0,064

DT= $\frac{2}{\sqrt{T}}$ = 0,161. En * significativos al 95 %.

3.B.18 Indra

3.B.18.1 Elección orden del VAR

Los estadísticos de Akaike y de Schwarz para diversos ordenes del VAR se presentan en la tabla 3.58. Los dos criterios no difieren, así que se estima un VAR(1) sin constante.

Tabla 3.58: Indra: Elección del orden del VAR

Retardos	1	2	3	4
AIC	-31,39	-31,21	-31,07	-30,88
SC	-30,81	-30,13	-29,48	-28,79

3.B.18.2 Estimación modelo VAR

Se estiman todos los parámetros de forma conjunta por mínimos cuadrados generalizados. Los resultados aparecen en la tabla 3.59.

Tabla 3.59: Indra: Estimación del VAR(1) ortogonalizado

Variable	Ecuaciones ^a				
dependiente	l_t	m_t	x_t	j_t	v_t
l_t	1,15 (0,07)	-0,21 (0,14)	0,21 (0,15)	-0,099 (0,116)	
m_t		1,15 (0,07)	-0,14 (0,14)	0,15 (0,11)	
x_t			0,99 (0,09)	-0,38 (0,09)	
j_t				1,26 (0,06)	
l_{t-1}	-0,028 (0,095)	-0,039 (0,081)	0,035 (0,09)	0,064 (0,101)	0,051 (0,08)
m_{t-1}	-0,057 (0,132)	0,0027 (0,1128)	-0,11 (0,13)	-0,071 (0,140)	-0,025 (0,110)
x_{t-1}	0,15 (0,11)	0,068 (0,099)	-0,030 (0,116)	0,088 (0,123)	-0,090 (0,097)
j_{t-1}	-0,26 (0,14)	-0,050 (0,125)	0,27 (0,15)	-0,19 (0,16)	0,14 (0,12)
v_{t-1}	1,19 (0,10)	-0,14 (0,12)	-0,099 (0,139)	0,053 (0,148)	-0,014 (0,116)

^aLa tabla muestra los coeficientes estimados del modelo VAR donde cada columna representa una ecuación del mismo. Entre paréntesis se presentan las desviaciones típicas.

La matriz de covarianzas se presenta en (3.18).

$$\Sigma_u = \begin{pmatrix} 1,20E-04 & 1,39E-04 & 1,34E-04 & 1,38E-04 & 1,32E-04 \\ 1,39E-04 & 2,47E-04 & 2,55E-04 & 2,46E-04 & 2,36E-04 \\ 1,34E-04 & 2,55E-04 & 3,83E-04 & 3,71E-04 & 3,46E-04 \\ 1,38E-04 & 2,46E-04 & 3,71E-04 & 4,93E-04 & 5,03E-04 \\ 1,32E-04 & 2,36E-04 & 3,46E-04 & 5,03E-04 & 6,05E-04 \end{pmatrix} \quad (3.18)$$

En la tabla 3.60 se presentan las funciones de correlación cruzadas. Sólo en dos de ellas se aprecian correlaciones significativas, por lo cual estos resultados sugieren que el modelo de la tabla 3.59 representa de forma adecuada la correlación dinámica entre las variables. Por su parte, los residuos del VAR(1) aparecen en el gráfico 3.22.

Tabla 3.60: Indra: Función de correlación cruzada residual del VAR(1)

Retardos	r_{11}	r_{12}	r_{13}	r_{14}	r_{15}
1	0,037	0,024	0,018	0,020	0,021
2	-0,078	-0,042	-0,002	-0,093	-0,128
3	0,010	-0,005	-0,022	-0,012	0,010
4	-0,092	-0,096	-0,076	-0,035	-0,034
5	-0,026	-0,093	-0,087	-0,072	-0,089
	r_{21}	r_{22}	r_{23}	r_{24}	r_{25}
1	0,017	0,004	0,005	0,002	0,007
2	-0,027	0,012	0,052	-0,057	-0,084
3	-0,035	-0,024	0,002	0,040	0,037
4	-0,034	-0,093	-0,102	-0,057	-0,025
5	0,031	-0,007	-0,037	-0,005	-0,030
	r_{31}	r_{32}	r_{33}	r_{34}	r_{35}
1	-0,048	-0,041	-0,026	-0,022	-0,013
2	-0,044	0,024	0,058	-0,071	-0,098
3	-0,091	-0,021	-0,023	0,031	0,018
4	-0,060	-0,086	-0,090	-0,046	-0,004
5	0,051	0,022	-0,026	0,007	0,001
	r_{41}	r_{42}	r_{43}	r_{44}	r_{45}
1	-0,075	-0,062	-0,045	-0,042	-0,030
2	-0,097	-0,011	0,050	-0,094	-0,127
3	-0,096	-0,077	-0,099	-0,047	-0,043
4	-0,162*	-0,135	-0,115	-0,098	-0,062
5	0,050	0,043	0,002	0,049	0,033
	r_{51}	r_{52}	r_{53}	r_{54}	r_{55}
1	-0,080	-0,066	-0,049	-0,052	-0,041
2	-0,116	-0,056	0,013	-0,100	-0,114
3	-0,132	-0,103	-0,131	-0,069	-0,046
4	-0,165*	-0,113	-0,096	-0,103	-0,080
5	0,066	0,062	0,035	0,077	0,037

DT = $\frac{2}{\sqrt{T}} = 0,161$. En * significativos al 95 %.

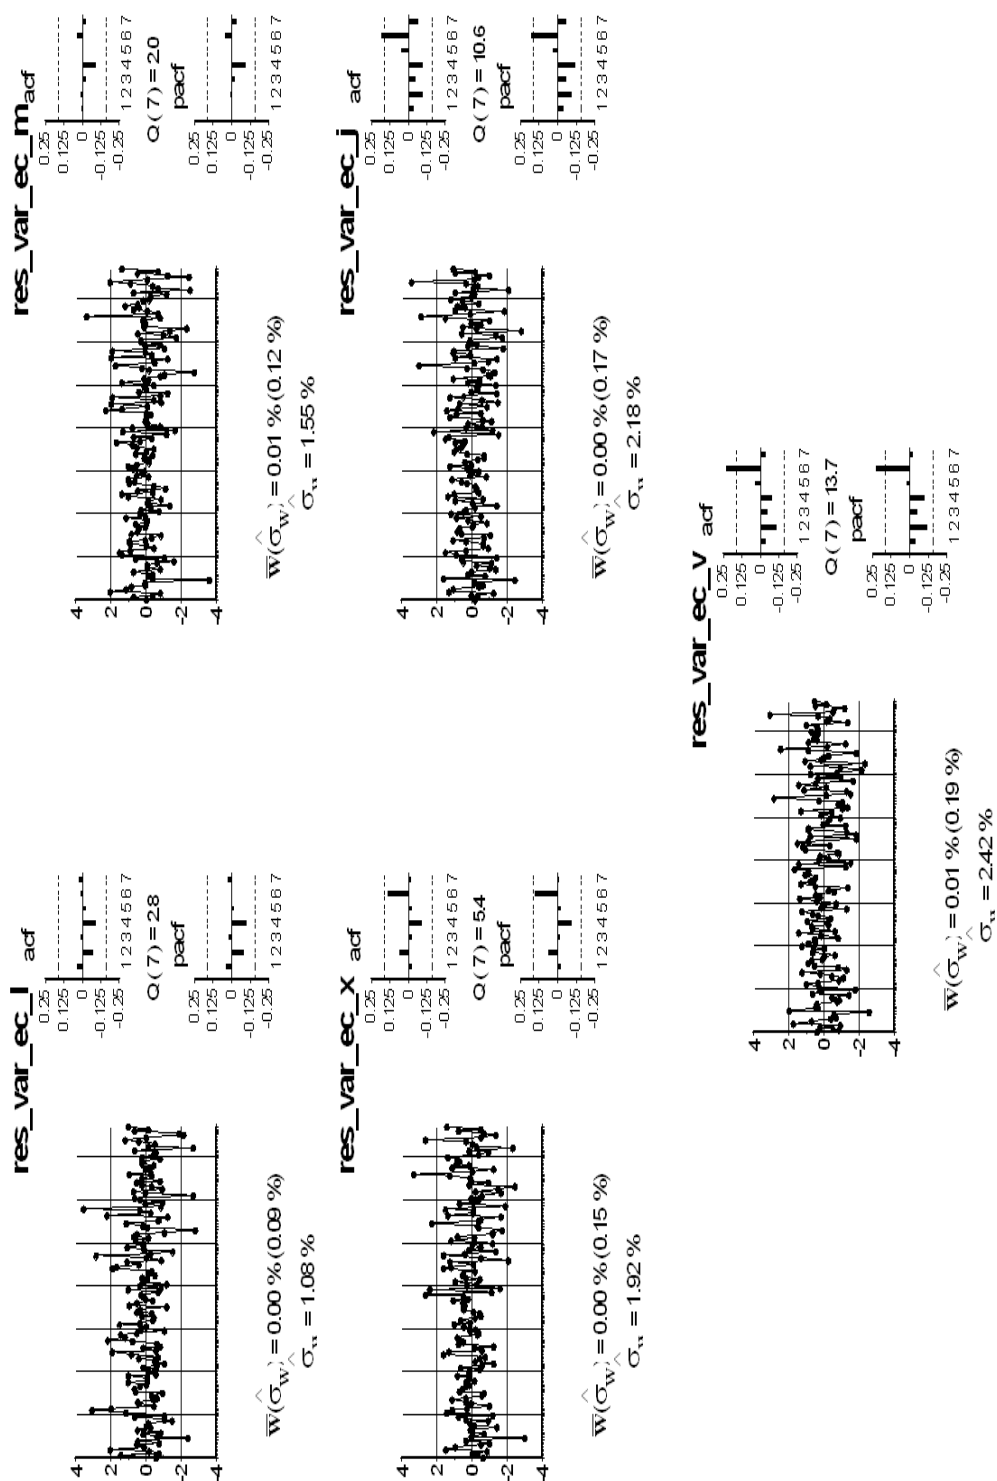


Gráfico 3.22: Indra: Residuos del VAR(1)

3.B.19 Inditex

3.B.19.1 Elección orden del VAR

En la tabla 3.61 se muestran los estadísticos de Akaike y de Schwarz para diversos ordenes del VAR.

Tabla 3.61: Inditex: Elección del orden del VAR

Retardos	1	2	3	4
AIC	-31,07	-30,94	-30,74	-30,74
SC	-30,48	-29,85	-29,16	-28,65

Los dos criterios coinciden en indicar que se debe estimar un VAR(1) con constante.

3.B.19.2 Estimación modelo VAR

Se estiman de forma conjunta todos los parámetros por mínimos cuadrados generalizados. Los resultados aparecen en la tabla 3.62.

Tabla 3.62: Inditex: Estimación del VAR(1) ortogonalizado

Variable dependiente	Ecuaciones ^a				
	l_t	m_t	x_t	j_t	v_t
μ	-0,0058 (0,0100)	-0,0024 (0,0093)	-0,0061 (0,0133)	0,025 (0,014)	-0,0053 (0,0098)
l_t		1,15 (0,07)	-0,062 (0,174)	0,087 (0,190)	-0,050 (0,109)
m_t			1,07 (0,12)	-0,25 (0,16)	0,090 (0,108)
x_t				1,16 (0,09)	-0,095 (0,088)
j_t					1,08 (0,05)
l_{t-1}	-0,16 (0,09)	0,042 (0,081)	0,26 (0,12)	-0,043 (0,129)	0,048 (0,086)
m_{t-1}	0,18 (0,11)	0,059 (0,102)	-0,21 (0,15)	0,030 (0,161)	0,073 (0,107)
x_{t-1}	-0,056 (0,089)	-0,13 (0,08)	-0,051 (0,120)	0,089 (0,131)	-0,15 (0,09)
j_{t-1}	0,17 (0,11)	0,15 (0,10)	-0,14 (0,14)	0,014 (0,157)	-0,029 (0,105)
v_{t-1}	0,87 (0,08)	-0,28 (0,10)	0,12 (0,15)	-0,091 (0,164)	0,043 (0,110)

^aLa tabla muestra los coeficientes estimados del modelo VAR donde cada columna representa una ecuación del mismo. Entre paréntesis se presentan las desviaciones típicas.

La matriz de covarianzas se presenta en (3.19).

$$\Sigma_u = \begin{pmatrix} 9,22E-05 & 1,06E-04 & 1,08E-04 & 1,07E-04 & 1,10E-04 \\ 1,06E-04 & 2,00E-04 & 2,09E-04 & 2,01E-04 & 2,09E-04 \\ 1,08E-04 & 2,09E-04 & 3,78E-04 & 3,95E-04 & 4,03E-04 \\ 1,07E-04 & 2,01E-04 & 3,95E-04 & 6,07E-04 & 6,28E-04 \\ 1,10E-04 & 2,09E-04 & 4,03E-04 & 6,28E-04 & 7,35E-04 \end{pmatrix} \quad (3.19)$$

En el gráfico 3.23 aparecen los residuos del VAR(1). Por otro lado, en la tabla 3.63 se presentan las funciones de correlación cruzadas. Una de ellas es significativa, y aunque se trata de r_{41} , en el primer retardo, se considera que no es necesario incrementar el orden del VAR(1) y que el modelo de la tabla 3.62 es adecuado para representar la relación entre las variables.

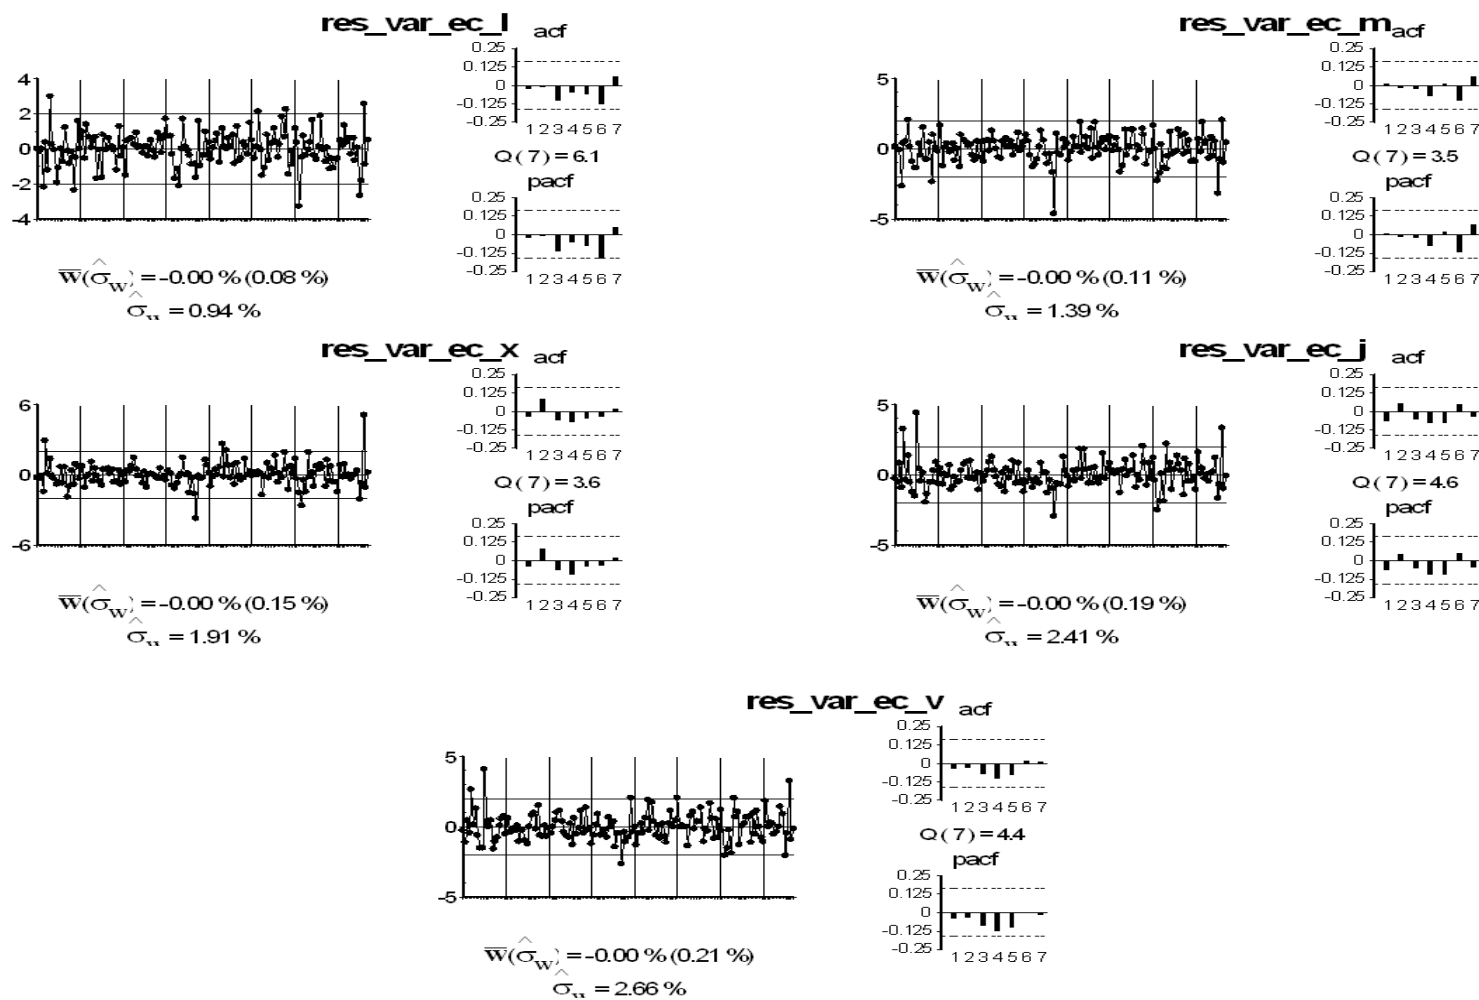


Gráfico 3.23: Inditex: Residuos del VAR(1)

Tabla 3.63: Inditex: Función de correlación cruzada residual del VAR(1)

Retardos	r_{11}	r_{12}	r_{13}	r_{14}	r_{15}
1	-0,027	-0,015	0,000	-0,005	0,009
2	-0,007	-0,041	0,124	0,103	0,037
3	-0,106	-0,018	0,000	0,075	0,079
4	-0,049	-0,131	-0,141	-0,065	-0,022
5	-0,063	-0,034	-0,026	-0,032	-0,011
	r_{21}	r_{22}	r_{23}	r_{24}	r_{25}
1	0,011	0,009	0,022	0,014	0,027
2	-0,011	-0,017	0,140	0,132	0,066
3	-0,128	-0,023	0,019	0,086	0,077
4	-0,012	-0,073	-0,095	-0,067	-0,058
5	0,036	0,011	0,002	-0,012	-0,014
	r_{31}	r_{32}	r_{33}	r_{34}	r_{35}
1	-0,104	-0,078	-0,042	-0,037	-0,022
2	-0,017	-0,044	0,085	0,090	0,005
3	-0,114	-0,037	-0,062	0,000	-0,018
4	-0,013	-0,060	-0,074	-0,107	-0,052
5	0,056	-0,002	-0,044	-0,054	-0,049
	r_{41}	r_{42}	r_{43}	r_{44}	r_{45}
1	-0,173*	-0,128	-0,078	-0,068	-0,049
2	-0,043	-0,078	0,055	0,053	-0,044
3	-0,068	-0,016	-0,084	-0,056	-0,077
4	0,102	0,044	-0,034	-0,082	-0,049
5	-0,011	0,020	-0,032	-0,084	-0,063
	r_{51}	r_{52}	r_{53}	r_{54}	r_{55}
1	-0,151	-0,114	-0,067	-0,057	-0,039
2	-0,063	-0,094	0,056	0,070	-0,033
3	-0,053	-0,002	-0,081	-0,043	-0,079
4	0,063	-0,005	-0,111	-0,144	-0,107
5	-0,035	0,032	-0,054	-0,101	-0,080

DT= $\frac{2}{\sqrt{T}} = 0,161$. En * significativos al 95 %.

3.B.20 Metrovacesa

3.B.20.1 Elección orden del VAR

En la tabla 3.64 se muestran los estadísticos de Akaike y de Schwarz para diversos ordenes del VAR. Los dos criterios difieren, mientras que el de Akaike indica que se debe estimar un VAR(3), Schwarz se inclina por un VAR(1). Se comienza

estimando un VAR(1) con constante, y será la función de correlación cruzada la que indique si es necesario incrementar el orden del VAR.

Tabla 3.64: Metrovacesa: Elección del orden del VAR

Retardos	1	2	3	4
AIC	-26,67	-26,63	-26,72	-26,68
SC	-26,08	-25,55	-25,14	-24,59

3.B.20.2 Estimación modelo VAR

Se estiman todos los parámetros de forma conjunta por mínimos cuadrados generalizados. Los resultados aparecen en la tabla 3.65.

Tabla 3.65: Metrovacesa: Estimación del VAR(1) ortogonalizado

Variable dependiente	Ecuaciones ^a				
	l_t	m_t	x_t	j_t	v_t
μ	-0,0015 (0,0115)	-0,0036 (0,0107)	0,023 (0,017)	-0,0066 (0,0174)	-0,011 (0,011)
l_t		1,28 (0,08)	-0,32 (0,20)	-0,16 (0,21)	-0,14 (0,13)
m_t			1,37 (0,13)	-0,21 (0,17)	0,20 (0,11)
x_t				1,09 (0,08)	-0,28 (0,07)
j_t					1,15 (0,05)
l_{t-1}	-0,33 (0,08)	0,037 (0,079)	0,26 (0,12)	-0,098 (0,130)	-0,073 (0,080)
m_{t-1}	0,41 (0,11)	-0,028 (0,107)	-0,23 (0,17)	0,13 (0,17)	0,17 (0,11)
x_{t-1}	-0,0092 (0,0824)	-0,35 (0,08)	0,011 (0,129)	0,33 (0,13)	-0,087 (0,083)
j_{t-1}	-0,15 (0,11)	0,36 (0,11)	-0,38 (0,18)	-0,43 (0,18)	0,095 (0,114)
v_{t-1}	1,08 (0,09)	-0,30 (0,12)	0,33 (0,19)	0,36 (0,19)	-0,027 (0,120)

^aLa tabla muestra los coeficientes estimados del modelo VAR donde cada columna representa una ecuación del mismo. Entre paréntesis se presentan las desviaciones típicas.

La matriz de covarianzas se presenta en (3.20).

$$\Sigma_u = \begin{pmatrix} 2,13E-04 & 2,74E-04 & 2,97E-04 & 2,32E-04 & 2,06E-04 \\ 2,74E-04 & 5,36E-04 & 6,29E-04 & 5,29E-04 & 4,96E-04 \\ 2,97E-04 & 6,29E-04 & 1,20E-03 & 1,13E-03 & 1,04E-03 \\ 2,32E-04 & 5,29E-04 & 1,13E-03 & 1,56E-03 & 1,54E-03 \\ 2,06E-04 & 4,96E-04 & 1,04E-03 & 1,54E-03 & 1,72E-03 \end{pmatrix} \quad (3.20)$$

Los residuos del VAR(1) aparecen en el gráfico 3.24. Por otro lado, en la tabla 3.66 se presentan las funciones de correlación cruzadas. En ella se aprecia que existen dudas si el VAR(1) es la mejor forma de representar estas cinco variables. Aparecen varias correlaciones significativas, en los retardos 2 y 3, existiendo una duda razonable en si se debe estimar un VAR(3), tal y como indicaba el criterio de Akaike. Al analizar las series en niveles y no poder hacer contraste de significatividad individual, el identificar un VAR(3) incrementa mucho el número de parámetros a estimar, por eso se decide estimar un VAR(1), ya que se piensa que el estimar un VAR(3) en niveles, llevará al contraste a rechazar más fácilmente la hipótesis nula de que el modelo univariante es la especificación correcta.

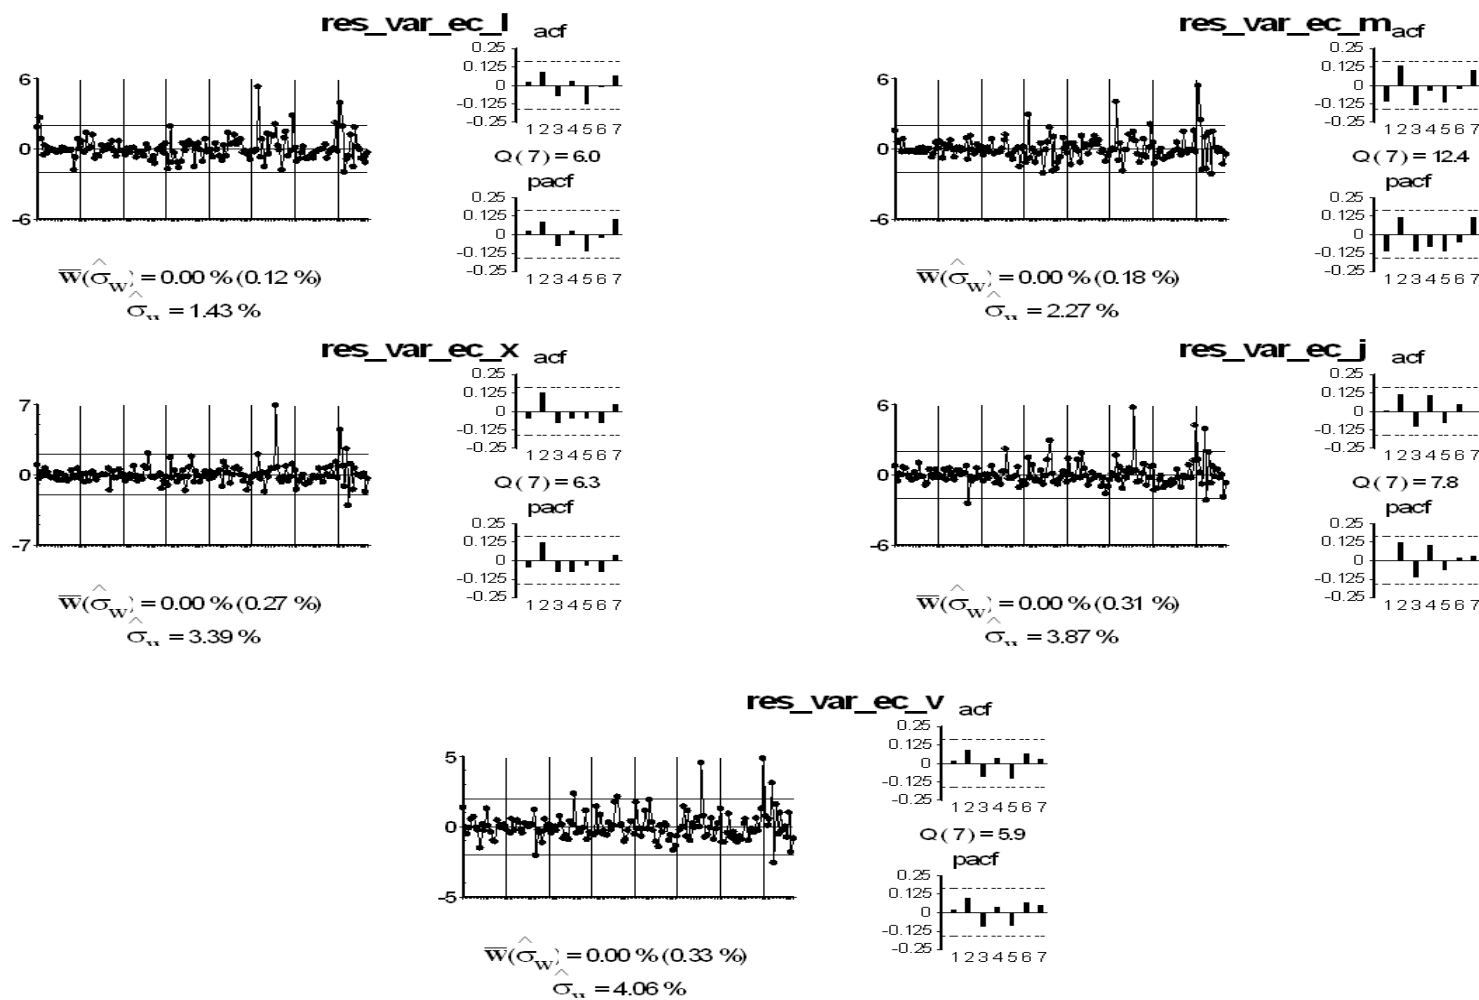


Gráfico 3.24: Metrovacesa: Residuos del VAR(1)

Tabla 3.66: Metrovacesa: Función de correlación cruzada residual del VAR(1)

Retardos	r_{11}	r_{12}	r_{13}	r_{14}	r_{15}
1	0,026	-0,057	-0,056	0,004	0,017
2	0,091	0,057	0,067	0,184*	0,181*
3	-0,078	-0,168*	-0,202*	-0,206*	-0,207*
4	0,030	0,013	0,079	0,065	-0,004
5	-0,125	-0,122	-0,006	-0,029	-0,043
	r_{21}	r_{22}	r_{23}	r_{24}	r_{25}
1	-0,028	-0,109	-0,091	-0,014	0,000
2	0,148	0,133	0,115	0,228*	0,216*
3	0,009	-0,136	-0,175*	-0,236*	-0,222*
4	-0,017	-0,043	-0,033	0,007	-0,035
5	-0,102	-0,122	-0,028	-0,082	-0,093
	r_{31}	r_{32}	r_{33}	r_{34}	r_{35}
1	-0,007	-0,062	-0,050	-0,003	0,003
2	0,168*	0,160	0,127	0,166*	0,142
3	-0,014	-0,070	-0,085	-0,157	-0,149
4	0,026	-0,072	-0,048	0,072	0,064
5	-0,098	-0,123	-0,048	-0,127	-0,127
	r_{41}	r_{42}	r_{43}	r_{44}	r_{45}
1	0,020	-0,038	-0,036	0,003	0,006
2	0,138	0,151	0,100	0,121	0,104
3	0,003	-0,040	-0,021	-0,108	-0,107
4	0,037	-0,043	-0,030	0,110	0,107
5	-0,060	-0,057	-0,001	-0,085	-0,087
	r_{51}	r_{52}	r_{53}	r_{54}	r_{55}
1	0,035	-0,007	0,003	0,025	0,022
2	0,150	0,176*	0,130	0,126	0,094
3	-0,023	-0,067	-0,047	-0,087	-0,092
4	0,011	-0,078	-0,064	0,051	0,043
5	-0,044	-0,062	-0,009	-0,106	-0,104

DT = $\frac{2}{\sqrt{T}} = 0,161$. En * significativos al 95 %.

3.B.21 Banco Popular

3.B.21.1 Elección orden del VAR

Los estadísticos de Akaike y de Schwarz para diversos ordenes del VAR aparecen en la tabla 3.67. Los dos criterios difieren, mientras que el de Akaike indica que se debe estimar un VAR(2), Schwarz se inclina por un VAR(1). Se comienza

estimando un VAR(1) con constante.

Tabla 3.67: Banco Popular: Elección del orden del VAR

Retardos	1	2	3	4
AIC	-34,63	-34,71	-34,58	-34,43
SC	-34,04	-33,63	-32,99	-32,39

3.B.21.2 Estimación modelo VAR

Se estiman todos los parámetros de forma conjunta por mínimos cuadrados generalizados. Los resultados aparecen en la tabla 3.68.

Tabla 3.68: Banco Popular: Estimación del VAR(1) ortogonalizado

Variable dependiente	Ecuaciones ^a				
	l_t	m_t	x_t	j_t	v_t
l_t		1,09 (0,08)	-0,12 (0,13)	0,15 (0,13)	0,031 (0,118)
m_t			1,07 (0,12)	-0,0066 (0,1367)	-0,095 (0,120)
x_t				0,89 (0,08)	-0,28 (0,10)
j_t					1,22 (0,07)
l_{t-1}	-0,090 (0,084)	0,052 (0,084)	-0,087 (0,093)	0,11 (0,09)	-0,11 (0,08)
m_{t-1}	0,097 (0,120)	-0,030 (0,119)	0,0069 (0,1323)	-0,16 (0,13)	0,095 (0,116)
x_{t-1}	-0,053 (0,101)	-0,17 (0,10)	0,21 (0,11)	0,0075 (0,1132)	-0,093 (0,100)
j_{t-1}	-0,17 (0,12)	0,13 (0,12)	-0,035 (0,136)	0,077 (0,136)	0,15 (0,12)
v_{t-1}	1,21 (0,08)	-0,079 (0,127)	-0,22 (0,14)	-0,063 (0,141)	0,086 (0,125)

^aLa tabla muestra los coeficientes estimados del modelo VAR donde cada columna representa una ecuación del mismo. Entre paréntesis se presentan las desviaciones típicas.

La matriz de covarianzas se presenta en (3.21).

$$\Sigma_u = \begin{pmatrix} 5,33E-05 & 5,84E-05 & 6,66E-05 & 6,70E-05 & 5,88E-05 \\ 5,84E-05 & 1,16E-04 & 1,38E-04 & 1,31E-04 & 1,11E-04 \\ 6,66E-05 & 1,38E-04 & 2,27E-04 & 2,12E-04 & 1,82E-04 \\ 6,70E-05 & 1,31E-04 & 2,12E-04 & 2,60E-04 & 2,46E-04 \\ 5,88E-05 & 1,11E-04 & 1,82E-04 & 2,46E-04 & 2,87E-04 \end{pmatrix} \quad (3.21)$$

En la tabla 3.69 se presentan las funciones de correlación cruzadas. Aunque aparecen cuatro correlaciones significativas en el tercer retardo, se considera que el modelo de la tabla 3.68 representa de forma adecuada la correlación dinámica entre las variables. Por otro lado, el gráfico 3.25 muestra los residuos del VAR(1).

Tabla 3.69: Banco Popular: Función de correlación cruzada residual del VAR(1)

Retardos	r_{11}	r_{12}	r_{13}	r_{14}	r_{15}
1	0,071	0,068	0,055	0,066	0,037
2	-0,012	0,014	0,006	-0,037	-0,024
3	0,136	0,165*	0,118	0,139	0,100
4	0,109	0,033	0,067	0,042	0,050
5	0,067	-0,004	-0,007	0,013	0,006
	r_{21}	r_{22}	r_{23}	r_{24}	r_{25}
1	0,152	0,115	0,087	0,092	0,074
2	0,027	0,042	-0,001	-0,028	-0,033
3	0,164*	0,181*	0,145	0,172*	0,113
4	0,155	0,074	0,091	0,091	0,103
5	0,047	0,002	-0,006	-0,001	0,006
	r_{31}	r_{32}	r_{33}	r_{34}	r_{35}
1	0,156	0,105	0,081	0,080	0,066
2	-0,029	-0,018	-0,024	-0,003	-0,013
3	0,041	0,026	-0,003	0,047	0,049
4	0,056	0,024	0,058	0,079	0,083
5	0,032	0,005	-0,004	0,001	0,039
	r_{41}	r_{42}	r_{43}	r_{44}	r_{45}
1	0,028	0,026	0,021	0,027	0,016
2	-0,033	-0,022	-0,046	-0,058	-0,097
3	0,022	-0,050	-0,084	0,004	0,034
4	0,080	0,032	0,063	0,100	0,113
5	0,030	0,016	0,004	0,014	0,044
	r_{51}	r_{52}	r_{53}	r_{54}	r_{55}
1	-0,071	-0,037	-0,032	-0,022	-0,038
2	-0,051	0,010	0,019	0,008	-0,063
3	-0,019	-0,064	-0,111	-0,021	0,015
4	0,128	0,054	0,073	0,090	0,090
5	0,020	0,009	0,012	0,035	0,054

DT = $\frac{2}{\sqrt{T}} = 0,161$. En * significativos al 95 %.

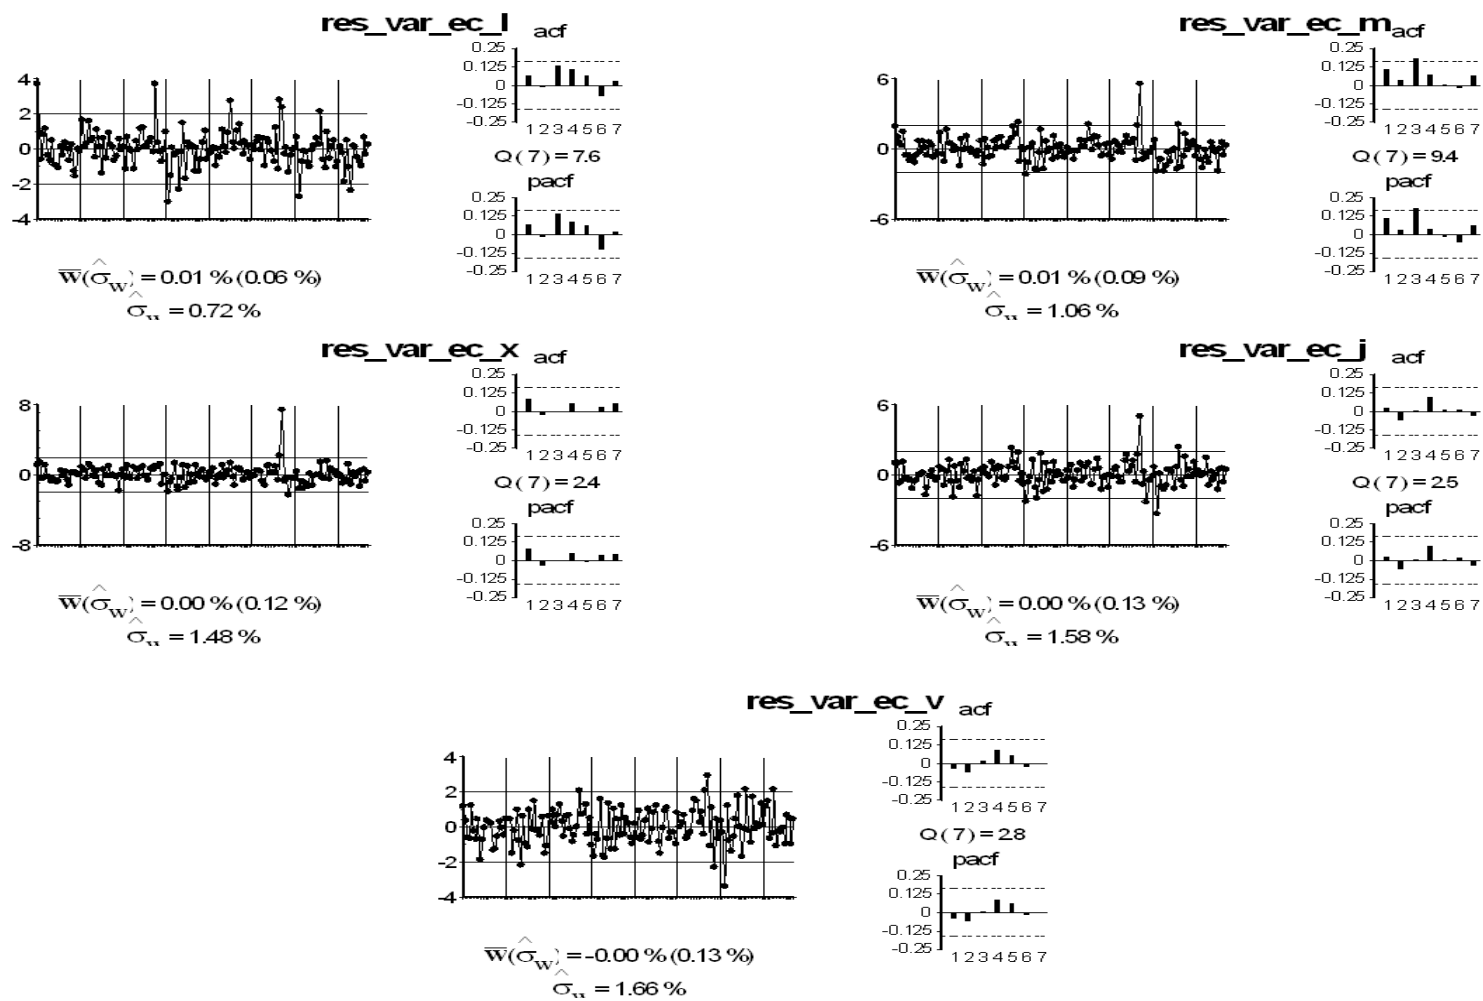


Gráfico 3.25: Banco Popular: Residuos del VAR(1)

3.B.22 Repsol

3.B.22.1 Elección orden del VAR

En la tabla 3.70 se muestran los estadísticos de Akaike y de Schwarz para diversos ordenes del VAR.

Tabla 3.70: Repsol: Elección del orden del VAR

Retardos	1	2	3	4
AIC	-30,85	-30,81	-30,78	-30,74
SC	-30,26	-29,72	-29,20	-28,65

Los dos criterios no difieren, por lo que se estima un VAR(1).

3.B.22.2 Estimación modelo VAR

Se estiman todos los parámetros de forma conjunta por mínimos cuadrados generalizados. Los resultados aparecen en la tabla 3.71.

Tabla 3.71: Repsol: Estimación del VAR(1) ortogonalizado

Variable dependiente	Ecuaciones ^a				
	l_t	m_t	x_t	j_t	v_t
l_t		0,99 (0,08)	-0,42 (0,09)	0,23 (0,13)	-0,17 (0,11)
m_t			1,25 (0,07)	-0,17 (0,16)	0,26 (0,13)
x_t				1,22 (0,11)	-0,31 (0,12)
j_t					1,19 (0,08)
l_{t-1}	-0,14 (0,08)	0,016 (0,086)	0,064 (0,069)	0,016 (0,092)	0,14 (0,07)
m_{t-1}	0,18 (0,14)	0,079 (0,150)	0,020 (0,121)	-0,22 (0,16)	-0,061 (0,132)
x_{t-1}	-0,13 (0,13)	-0,028 (0,132)	-0,12 (0,11)	0,25 (0,14)	-0,19 (0,12)
j_{t-1}	0,18 (0,13)	0,072 (0,131)	0,044 (0,106)	-0,24 (0,14)	-0,027 (0,116)
v_{t-1}	0,92 (0,09)	-0,14 (0,12)	0,16 (0,10)	-0,093 (0,130)	0,17 (0,11)

^aLa tabla muestra los coeficientes estimados del modelo VAR donde cada columna representa una ecuación del mismo. Entre paréntesis se presentan las desviaciones típicas.

La matriz de covarianzas se presenta en (3.22).

$$\Sigma_u = \begin{pmatrix} 1,27E-04 & 1,26E-04 & 1,04E-04 & 1,34E-04 & 1,38E-04 \\ 1,26E-04 & 2,59E-04 & 2,71E-04 & 3,15E-04 & 3,36E-04 \\ 1,04E-04 & 2,71E-04 & 3,83E-04 & 4,44E-04 & 4,61E-04 \\ 1,34E-04 & 3,15E-04 & 4,44E-04 & 6,71E-04 & 7,18E-04 \\ 1,38E-04 & 3,36E-04 & 4,61E-04 & 7,18E-04 & 8,73E-04 \end{pmatrix} \quad (3.22)$$

El gráfico 3.26 muestra los residuos del VAR(1). Por otro lado, en la tabla 3.72 se presentan las funciones de correlación cruzadas. En cinco de ellas, en el segundo retardo, se aprecian correlaciones significativas, sin embargo, se considera que la forma adecuada de representar la relación entre las variables es el modelo que aparece en la tabla 3.71.

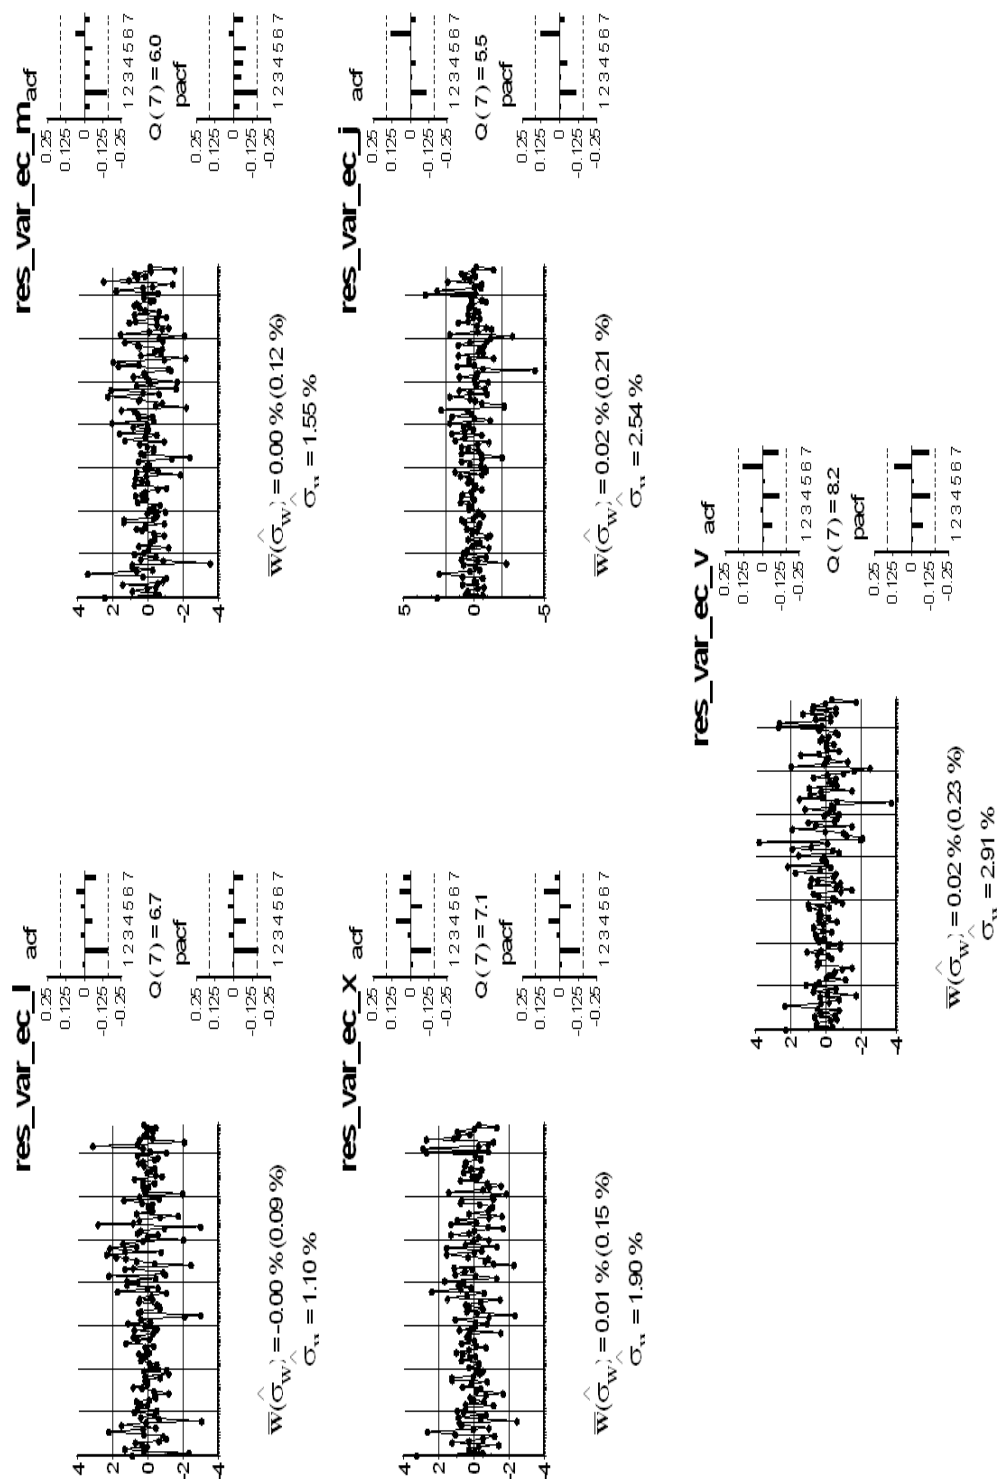


Gráfico 3.26: Repsol: Residuos del VAR(1)

Tabla 3.72: Repsol: Función de correlación cruzada residual del VAR(1)

Retardos	r_{11}	r_{12}	r_{13}	r_{14}	r_{15}
1	0,010	-0,034	-0,041	-0,017	-0,025
2	-0,166*	-0,125	-0,103	-0,095	-0,076
3	0,023	0,019	0,102	0,104	0,080
4	-0,051	-0,111	-0,069	-0,109	-0,127
5	0,028	0,023	-0,016	0,041	0,036
	r_{21}	r_{22}	r_{23}	r_{24}	r_{25}
1	-0,002	-0,036	-0,028	-0,013	-0,012
2	-0,164*	-0,158	-0,133	-0,101	-0,085
3	0,014	-0,042	-0,024	-0,021	-0,019
4	0,004	-0,038	0,032	-0,067	-0,096
5	-0,040	-0,054	-0,049	0,020	0,030
	r_{31}	r_{32}	r_{33}	r_{34}	r_{35}
1	-0,008	-0,035	-0,018	-0,007	-0,004
2	-0,180*	-0,171	-0,141	-0,105	-0,088
3	0,070	0,027	0,019	0,008	0,016
4	0,086	0,032	0,095	-0,023	-0,058
5	-0,0579	-0,070	-0,080	-0,006	0,025
	r_{41}	r_{42}	r_{43}	r_{44}	r_{45}
1	-0,008	-0,038	-0,023	-0,012	-0,009
2	-0,189*	-0,168*	-0,143	-0,109	-0,091
3	0,048	-0,003	0,001	-0,012	-0,001
4	0,039	-0,000	0,051	-0,042	-0,075
5	0,008	-0,022	-0,048	0,005	0,026
	r_{51}	r_{52}	r_{53}	r_{54}	r_{55}
1	0,000	-0,039	-0,029	-0,012	-0,013
2	-0,136	-0,127	-0,110	-0,092	-0,071
3	-0,006	-0,035	0,009	0,000	0,012
4	0,032	-0,021	0,023	-0,073	-0,120
5	0,001	-0,045	-0,077	-0,029	-0,016

DT = $\frac{2}{\sqrt{T}} = 0,161$. En * significativos al 95 %.

3.B.23 Banco Santander

3.B.23.1 Elección orden del VAR

En la tabla 3.73 se muestran los estadísticos de Akaike y de Schwarz para diversos ordenes del VAR. Al no diferir los dos criterios se estima un VAR(1).

Tabla 3.73: Banco Santander: Elección del orden del VAR

Retardos	1	2	3	4
AIC	-32,79	-32,75	-32,63	-32,41
SC	-32,20	-31,66	-31,04	-30,32

3.B.23.2 Estimación modelo VAR

Se estiman todos los parámetros de forma conjunta por mínimos cuadrados generalizados. Los resultados aparecen en la tabla 3.74.

Tabla 3.74: Banco Santander: Estimación del VAR(1) ortogonalizado

Variable dependiente	Ecuaciones ^a				
	l_t	m_t	x_t	j_t	v_t
l_t		0,92 (0,07)	-0,17 (0,11)	0,15 (0,12)	0,18 (0,11)
m_t			1,05 (0,10)	-0,076 (0,13)	-0,15 (0,12)
x_t				1,06 (0,09)	-0,23 (0,11)
j_t					1,19 (0,08)
l_{t-1}	-0,31 (0,12)	0,045 (0,084)	-0,10 (0,10)	-0,062 (0,104)	0,013 (0,096)
m_{t-1}	0,44 (0,16)	-0,083 (0,114)	0,018 (0,134)	0,066 (0,139)	-0,098 (0,130)
x_{t-1}	-0,088 (0,140)	0,043 (0,098)	0,12 (0,11)	-0,021 (0,121)	0,074 (0,112)
j_{t-1}	-0,43 (0,15)	0,0083 (0,1114)	-0,045 (0,131)	0,057 (0,136)	-0,11 (0,13)
v_{t-1}	1,39 (0,10)	0,059 (0,108)	0,13 (0,13)	-0,17 (0,13)	0,13 (0,12)

^aLa tabla muestra los coeficientes estimados del modelo VAR donde cada columna representa una ecuación del mismo. Entre paréntesis se presentan las desviaciones típicas.

La matriz de covarianzas se presenta en (3.23).

$$\Sigma_u = \begin{pmatrix} 1,17E-04 & 1,08E-04 & 9,37E-05 & 1,08E-04 & 1,13E-04 \\ 1,08E-04 & 1,58E-04 & 1,47E-04 & 1,60E-04 & 1,53E-04 \\ 9,37E-05 & 1,47E-04 & 2,17E-04 & 2,32E-04 & 2,22E-04 \\ 1,08E-04 & 1,60E-04 & 2,32E-04 & 3,35E-04 & 3,42E-04 \\ 1,13E-04 & 1,53E-04 & 2,22E-04 & 3,42E-04 & 4,27E-04 \end{pmatrix} \quad (3.23)$$

En la tabla 3.75 se presentan las funciones de correlación cruzadas. Dos de ellas son estadísticamente distintas de 0, y aunque corresponden con primeros retardos, se considera que el modelo de la tabla 3.74 representa de forma adecuada la correlación dinámica entre las variables. Por su parte, el gráfico 3.27 muestra los residuos del VAR(1).

Tabla 3.75: Banco Santander: Función de correlación cruzada residual del VAR(1)

Retardos	r_{11}	r_{12}	r_{13}	r_{14}	r_{15}
1	-0,049	-0,042	-0,037	-0,033	-0,029
2	-0,008	0,017	0,034	0,086	0,045
3	-0,060	-0,039	-0,006	0,045	0,058
4	-0,055	0,001	0,098	0,082	0,102
5	0,004	0,055	0,050	0,019	0,039
	r_{21}	r_{22}	r_{23}	r_{24}	r_{25}
1	-0,065	-0,055	-0,048	-0,041	-0,029
2	0,052	0,100	0,053	0,077	0,016
3	-0,064	-0,043	-0,023	0,024	0,024
4	-0,054	0,001	0,071	0,112	0,141
5	-0,050	-0,023	-0,048	-0,051	-0,052
	r_{31}	r_{32}	r_{33}	r_{34}	r_{35}
1	-0,174*	-0,149	-0,132	-0,115	-0,094
2	0,044	0,115	0,104	0,105	0,016
3	-0,012	-0,003	0,017	0,040	0,000
4	-0,083	-0,012	0,024	0,053	0,089
5	-0,020	-0,013	-0,093	-0,078	-0,068
	r_{41}	r_{42}	r_{43}	r_{44}	r_{45}
1	-0,177*	-0,153	-0,137	-0,117	-0,098
2	-0,015	0,038	0,069	0,080	-0,011
3	0,021	-0,026	0,002	0,032	0,044
4	-0,131	-0,088	-0,035	-0,023	0,006
5	-0,017	-0,026	-0,072	-0,087	-0,081
	r_{51}	r_{52}	r_{53}	r_{54}	r_{55}
1	-0,142	-0,130	-0,120	-0,101	-0,080
2	-0,006	0,017	0,078	0,110	-0,013
3	0,020	-0,027	-0,013	-0,006	-0,011
4	-0,112	-0,099	-0,049	-0,047	-0,011
5	-0,019	0,002	-0,046	-0,086	-0,083

$DT = \frac{2}{\sqrt{T}} = 0,161$. En * significativos al 95 %.

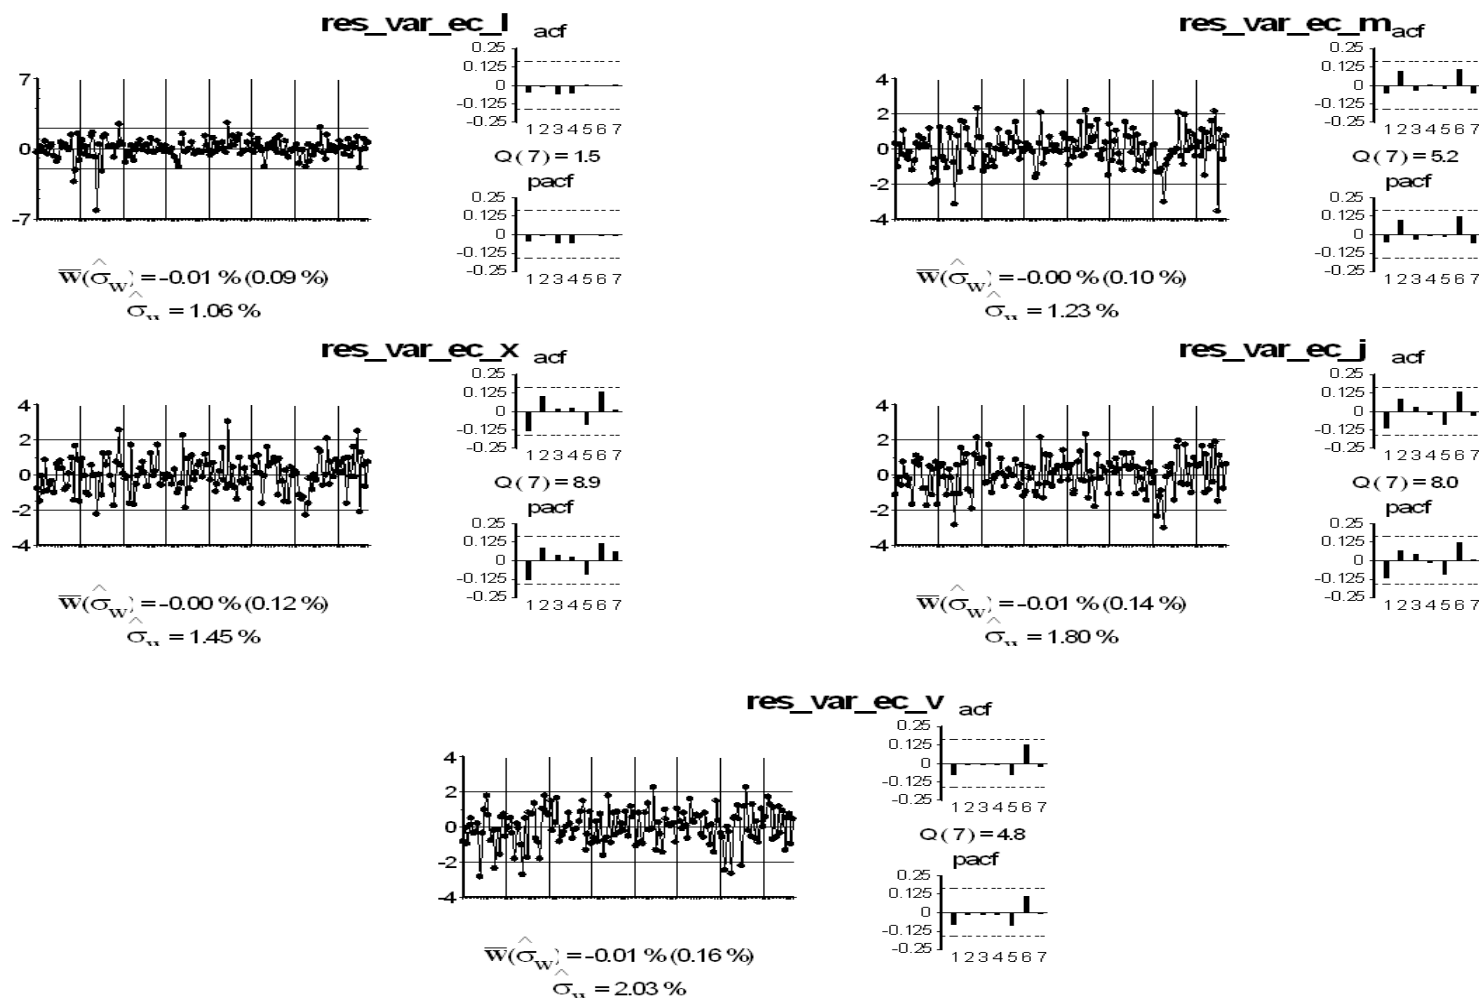


Gráfico 3.27: Banco Santander: Residuos del VAR(1)

3.B.24 Telefónica

3.B.24.1 Elección orden del VAR

En la tabla 3.76 se muestran los estadísticos de Akaike y de Schwarz para diversos ordenes del VAR.

Tabla 3.76: Telefónica: Elección del orden del VAR

Retardos	1	2	3	4
AIC	-33,39	-33,27	-33,15	-32,97
SC	-32,90	-32,28	-31,67	-30,88

Los dos criterios indican que se debe estimar un VAR(1)

3.B.24.2 Estimación modelo VAR

Se estiman todos los parámetros de forma conjunta por mínimos cuadrados generalizados. Los resultados aparecen en la tabla 3.77.

Tabla 3.77: Telefónica: Estimación del VAR(1) ortogonalizado

Variable dependiente	Ecuaciones ^a				
	l_t	m_t	x_t	j_t	v_t
l_t		0,90 (0,07)	-0,045 (0,114)	0,036 (0,116)	0,056 (0,127)
m_t			1,02 (0,09)	-0,064 (0,124)	-0,13 (0,13)
x_t				1,12 (0,08)	-0,11 (0,14)
j_t					1,21 (0,09)
l_{t-1}	-0,17 (0,09)	0,13 (0,0)	0,0050 (0,0880)	0,039 (0,089)	-0,11 (0,10)
m_{t-1}	0,34 (0,12)	-0,16 (0,11)	-0,080 (0,122)	-0,050 (0,124)	0,018 (0,136)
x_{t-1}	-0,28 (0,12)	-0,16 (0,11)	0,19 (0,12)	-0,089 (0,127)	0,17 (0,14)
j_{t-1}	-0,087 (0,12)	0,27 (0,11)	-0,047 (0,122)	0,14 (0,12)	-0,12 (0,14)
v_{t-1}	1,19 (0,07)	0,0058 (0,1124)	-0,044 (0,121)	-0,12 (0,12)	0,0038 (0,1356)

^aLa tabla muestra los coeficientes estimados del modelo VAR donde cada columna representa una ecuación del mismo. Entre paréntesis se presentan las desviaciones típicas.

La matriz de covarianzas se presenta en (3.24).

$$\Sigma_u = \begin{pmatrix} 7,22E-05 & 6,53E-05 & 6,33E-05 & 6,91E-05 & 7,26E-05 \\ 6,53E-05 & 1,19E-04 & 1,18E-04 & 1,27E-04 & 1,29E-04 \\ 6,33E-05 & 1,18E-04 & 1,88E-04 & 2,04E-04 & 2,15E-04 \\ 6,91E-05 & 1,27E-04 & 2,04E-04 & 2,94E-04 & 3,21E-04 \\ 7,26E-05 & 1,29E-04 & 2,15E-04 & 3,21E-04 & 4,39E-04 \end{pmatrix} \quad (3.24)$$

Los residuos del VAR(1) aparecen en el gráfico 3.28. Por otro lado, en la tabla 3.78 se presentan las funciones de correlación cruzadas. Seis de ellas son significativas, y salvo por la r_{21} , todas las demás sugieren que el modelo de la tabla 3.77 representa de forma adecuada la correlación dinámica entre las variables.

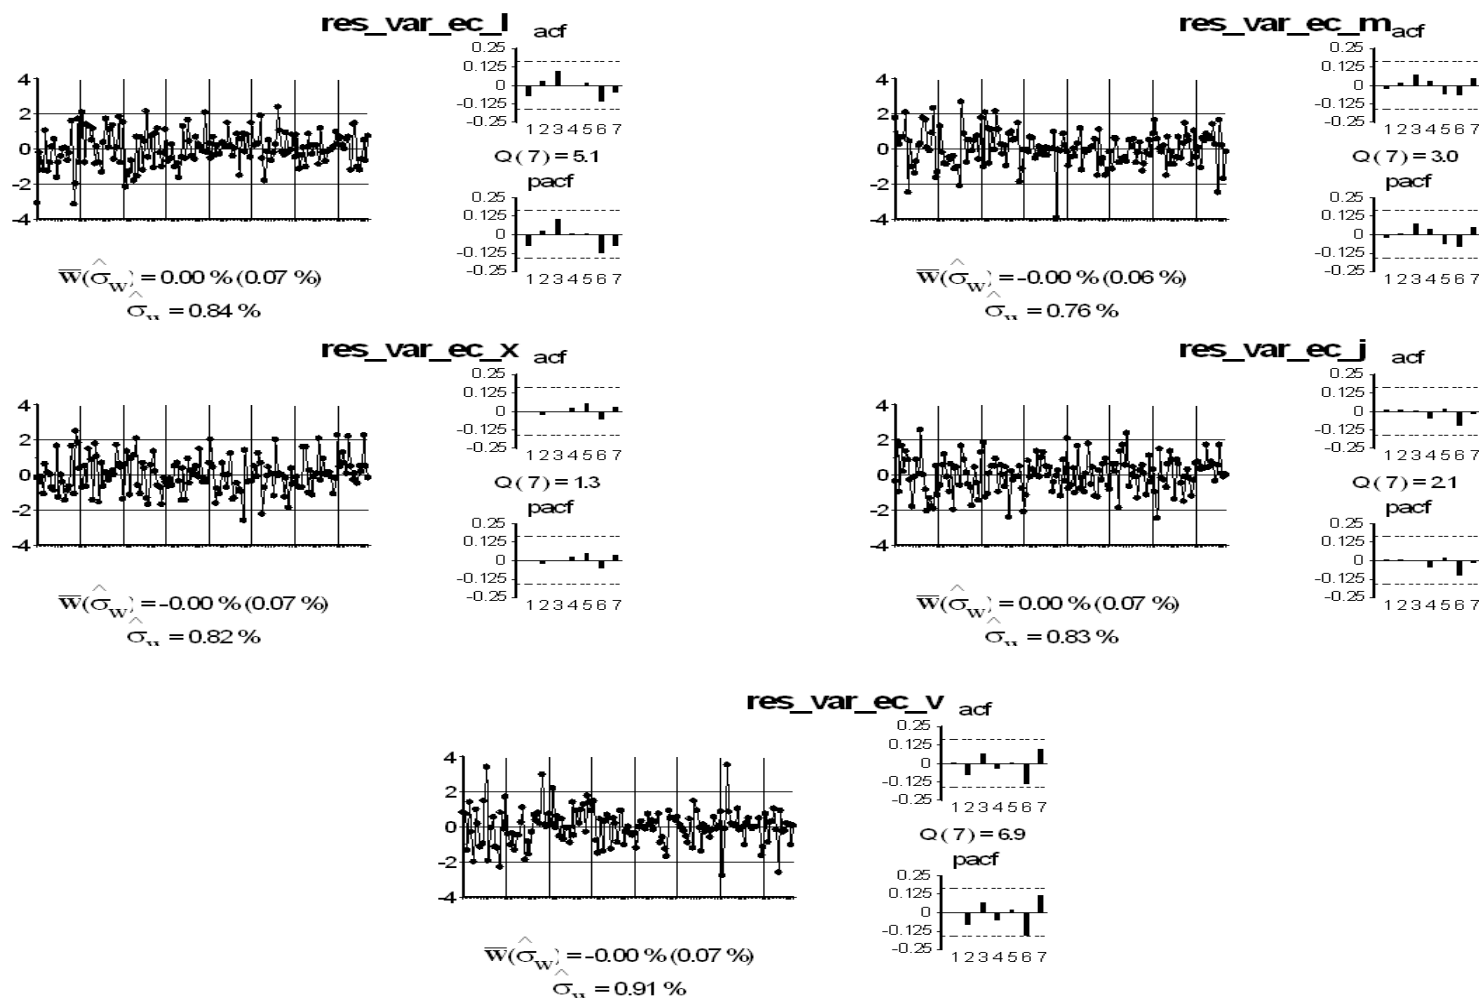


Gráfico 3.28: Telefónica: Residuos del VAR(1)

Tabla 3.78: Telefónica: Función de correlación cruzada residual del VAR(1)

Retardos	r_{11}	r_{12}	r_{13}	r_{14}	r_{15}
1	-0,076	-0,043	0,053	0,041	0,017
2	0,034	-0,130	0,051	0,023	-0,025
3	0,097	0,026	0,025	0,069	-0,032
4	-0,003	-0,097	-0,071	-0,033	0,050
5	0,016	-0,113	0,068	-0,085	-0,088
	r_{21}	r_{22}	r_{23}	r_{24}	r_{25}
1	-0,168*	-0,027	-0,029	-0,015	0,007
2	-0,005	0,015	0,020	0,061	-0,022
3	-0,055	0,076	0,101	-0,008	0,191*
4	-0,096	0,031	-0,004	-0,017	0,090
5	-0,113	-0,062	-0,051	-0,016	-0,005
	r_{31}	r_{32}	r_{33}	r_{34}	r_{35}
1	-0,060	0,026	-0,003	0,017	-0,015
2	-0,045	0,100	-0,024	-0,049	0,051
3	0,046	-0,094	-0,006	-0,146	-0,145
4	0,121	0,184*	0,023	0,049	0,039
5	-0,065	-0,071	0,052	0,075	0,006
	r_{41}	r_{42}	r_{43}	r_{44}	r_{45}
1	-0,095	-0,026	0,002	0,008	0,006
2	-0,026	0,011	-0,021	0,014	-0,089
3	0,017	-0,180*	0,062	0,006	0,052
4	-0,106	-0,103	0,224*	-0,045	-0,036
5	-0,064	0,002	0,089	0,016	-0,011
	r_{51}	r_{52}	r_{53}	r_{54}	r_{55}
1	-0,133	-0,026	-0,033	0,002	0,007
2	0,055	0,026	0,064	-0,016	-0,083
3	-0,042	0,035	-0,091	-0,172*	0,067
4	0,123	0,004	-0,053	0,023	-0,042
5	0,052	0,012	0,035	0,018	0,004

DT = $\frac{2}{\sqrt{T}} = 0,161$. En * significativos al 95 %.

3.B.25 Unión Fenosa

3.B.25.1 Elección orden del VAR

En la tabla 3.79 se muestran los estadísticos de Akaike y de Schwarz para diversos ordenes del VAR. Los dos criterios difieren, mientras que el de Akaike no discrimina entre un VAR(1) o un VAR(3), Schwarz se inclina por un VAR(1). Se

comienza estimando un VAR(1) con constante.

Tabla 3.79: Unión Fenosa: Elección del orden del VAR

Retardos	1	2	3	4
AIC	-30,99	-30,92	-30,99	-30,91
SC	-30,40	-29,83	-29,41	-28,82

3.B.25.2 Estimación modelo VAR

Se estiman todos los parámetros de forma conjunta por mínimos cuadrados generalizados. Los resultados aparecen en la tabla 3.80.

Tabla 3.80: Unión Fenosa: Estimación del VAR(1) ortogonalizado

Variable dependiente	Ecuaciones ^a				
	l_t	m_t	x_t	j_t	v_t
μ	-0,0019 (0,0077)	0,0056 (0,0065)	0,0034 (0,0052)	0,0074 (0,0068)	0,0064 (0,0064)
l_t		0,87 (0,07)	-0,069 (0,080)	0,015 (0,104)	-0,040 (0,097)
m_t			1,00 (0,06)	-0,21 (0,14)	0,21 (0,13)
x_t				1,26 (0,11)	-0,15 (0,14)
j_t					0,97 (0,08)
l_{t-1}	-0,13 (0,09)	-0,032 (0,078)	0,0027 (0,0631)	-0,050 (0,082)	-0,088 (0,076)
m_{t-1}	-0,025 (0,155)	0,13 (0,13)	0,076 (0,106)	0,12 (0,14)	0,085 (0,128)
x_{t-1}	0,15 (0,17)	0,087 (0,143)	-0,17 (0,11)	-0,16 (0,15)	-0,062 (0,140)
j_{t-1}	-0,12 (0,13)	-0,35 (0,11)	0,029 (0,095)	0,12 (0,12)	0,160 (0,115)
v_{t-1}	1,14 (0,10)	0,29 (0,11)	0,12 (0,09)	-0,099 (0,124)	-0,083 (0,115)

^aLa tabla muestra los coeficientes estimados del modelo VAR donde cada columna representa una ecuación del mismo. Entre paréntesis se presentan las desviaciones típicas.

La matriz de covarianzas se presenta en (3.25).

$$\Sigma_u = \begin{pmatrix} 1,17E-04 & 1,08E-04 & 9,37E-05 & 1,08E-04 & 1,13E-04 \\ 1,08E-04 & 1,58E-04 & 1,47E-04 & 1,60E-04 & 1,53E-04 \\ 9,37E-05 & 1,47E-04 & 2,17E-04 & 2,32E-04 & 2,22E-04 \\ 1,08E-04 & 1,60E-04 & 2,32E-04 & 3,35E-04 & 3,42E-04 \\ 1,13E-04 & 1,53E-04 & 2,22E-04 & 3,42E-04 & 4,27E-04 \end{pmatrix} \quad (3.25)$$

Los residuos del VAR(1) aparecen en el gráfico 3.29. Por otro lado, en la tabla 3.81 se presentan las funciones de correlación cruzadas. En cuatro de ellas se aprecian correlaciones significativas, sin embargo, se considera que el modelo de la tabla 3.80 representa de forma adecuada la correlación dinámica entre las variables.

Tabla 3.81: Unión Fenosa: Función de correlación cruzada residual del VAR(1)

Retardos	r_{11}	r_{12}	r_{13}	r_{14}	r_{15}
1	-0,044	-0,066	-0,059	-0,038	-0,023
2	-0,111	-0,157	-0,149	-0,171*	-0,074
3	0,056	0,095	-0,001	0,006	0,087
4	-0,112	-0,165*	-0,137	-0,126	-0,084
5	-0,013	-0,070	-0,067	-0,056	-0,101
	r_{21}	r_{22}	r_{23}	r_{24}	r_{25}
1	-0,026	-0,032	-0,022	-0,009	-0,004
2	-0,109	-0,109	-0,054	-0,083	-0,049
3	-0,034	-0,005	-0,051	-0,006	0,003
4	-0,037	-0,044	-0,040	-0,054	-0,031
5	0,088	0,061	0,039	0,027	-0,037
	r_{31}	r_{32}	r_{33}	r_{34}	r_{35}
1	-0,047	-0,046	-0,031	-0,017	-0,013
2	-0,044	-0,028	0,046	-0,008	0,018
3	0,065	0,071	-0,015	0,002	0,001
4	0,016	-0,025	-0,033	-0,032	-0,019
5	0,090	0,045	0,005	0,000	-0,043
	r_{41}	r_{42}	r_{43}	r_{44}	r_{45}
1	-0,019	-0,029	-0,016	-0,005	-0,006
2	0,068	0,104	0,113	0,027	0,031
3	0,080	0,121	0,026	0,033	0,052
4	0,061	0,024	-0,009	-0,031	-0,040
5	0,004	-0,067	-0,113	-0,135	-0,164*
	r_{51}	r_{52}	r_{53}	r_{54}	r_{55}
1	-0,019	-0,029	-0,016	-0,005	-0,006
2	0,068	0,104	0,113	0,027	0,031
3	0,080	0,120	0,026	0,033	0,052
4	0,061	0,024	-0,009	-0,031	-0,040
5	0,004	-0,067	-0,113	-0,135	-0,164*

DT = $\frac{2}{\sqrt{T}} = 0,161$. En * significativos al 95 %.

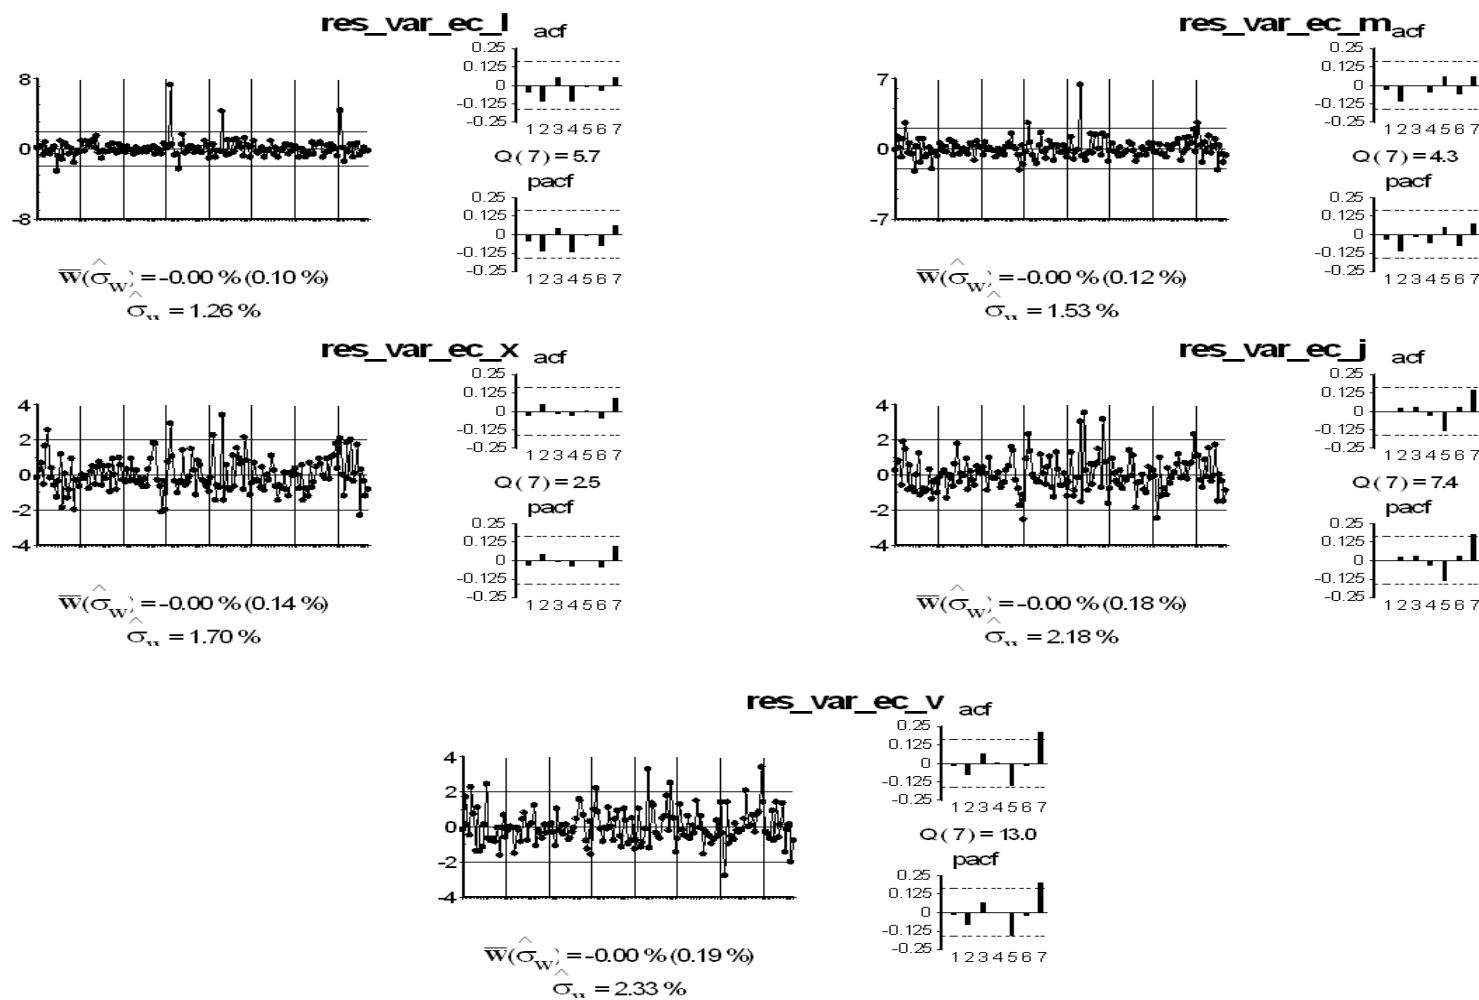


Gráfico 3.29: Unión Fenosa: Residuos del VAR(1)

Capítulo 4

Experimento II: Caso restringido

4.1 Introducción

En este capítulo, se compara la precisión predictiva de los modelos periódicos restringidos del estilo de los aplicados por Novales y Flores (1997), con los modelos univariantes simples.

Los modelos univariantes son los mismos que los presentados en el capítulo anterior, ya que las series objeto de estudio son las mismas.

En el anterior capítulo, los modelos VAR con las series en niveles no mejoraban las previsiones de los modelos univariantes, en casi ninguno de los casos. Se modelizan ahora las series estacionarias para poder contrastar la significatividad de los parámetros del modelo.

Al realizar el análisis univariante de las series diarias, todas ellas son $I(1)$. El modelo periódico se construye sobre las cinco series, que son cada uno de los días laborables de una semana. Si se toma una diferencia regular sobre las series de los días, es similar a tomar una diferencial estacional a la serie diaria. Por ello se estima un modelo periódico de corrección del error del tipo de los aplicados en Franses y Romijn (1993).

Para construir este modelo VEC, se parte del orden del modelo VAR estimado en el capítulo anterior. Al eliminar los parámetros no significativos, se observa en

los gráficos de los residuos y en la función de correlación cruzada, que en muchos casos hay que incrementar el orden del VEC estimado.

Posteriormente, a estos modelos se les aplica el contraste de estacionalidad univariante desarrollado por Flores y Novales (1997) y se compara la precisión a la hora de prever de los modelos seleccionados por el contraste, tanto dentro de la muestra, como fuera de ella.

El capítulo finaliza comprobando la posibilidad de construir modelos compuestos, y estudiando la capacidad predictiva de éstos.

4.2 Estimación modelos VEC

Para el estudio de las relaciones de cointegración en el vector de variables en niveles $(l_t, m_t, x_t, j_t, v_t)$, se usa el método de Engle y Granger (1987). Para ello se representan gráficamente las relaciones de cointegración obtenidas del contraste y se estudia su estacionariedad. Por el método de Engle y Granger se obtienen cuatro relaciones de cointegración para todas las series.

Estas cuatro relaciones de cointegración son las que aparecen en Franses y Romijn (1993) e indican que las series diarias son $I(1)$.

Se comienza identificando modelos $VEC(0)$, ya que se parte de los $VAR(1)$ estimados en el capítulo anterior. Al ser ahora las series estacionarias, se pueden eliminar los parámetros no significativos de los modelos. Al hacer esto aparecen correlaciones significativas en los retardos de las funciones de correlación cruzadas, lo que hace que se incremente el orden del VEC.

En el apéndice 4.A aparecen, para cada una de las series y de forma detallada, el estudio de la existencia de las relaciones de cointegración, el VEC estimado restringido, con el gráfico de los residuos y la tabla con los valores de las funciones de correlación cruzadas, y el VEC ortogonalizado, que es la representación del modelo compuesto.

4.3 Contraste

En esta sección se aplica el contraste de estacionalidad desarrollado por Flores y Novales (1997) a las variables modelizadas en la sección anterior. Los resultados aparecen en la tabla 4.1.

Tabla 4.1: Contraste de estacionalidad univariante

Valores	$\ln Lr$	$\ln Lsr$	Estadístico ^a	VEC(p)
IBEX	-51,15	-50,70	72,75	0
ABE	-47,03	-46,56	72,38*	1
ACS	-46,60	-45,79	124,16	2
ACX	-45,31	-44,85	71,35*	2
ALT	-46,22	-45,67	83,61*	2
ANA	-43,64	-43,25	59,82*	1
BBVA	-47,15	-46,36	121,75	1
BKT	-45,88	-45,32	87,56	0
BTO	-48,27	-47,27	154,46	2
ELE	-45,85	-44,93	141,87	1
ENG	-46,50	-45,32	181,23	2
FCC	-45,69	-44,92	117,50	2
FER	-43,89	-43,74	24,74*	2
GAM	-42,78	-42,50	43,22*	0
GAS	-47,09	-46,15	147,11	1
IBE	-47,22	-46,46	118,44	1
IBLA	-42,73	-42,61	17,97*	0
IDR	-45,90	-45,59	46,99*	0
ITX	-45,48	-44,65	70,63	0
MVC	-41,75	-39,69	313,71	2
POP	-49,40	-48,74	102,56	1
REP	-45,81	-45,00	124,82	2
SAN	-47,55	-46,79	117,32	1
TEF	-48,05	-47,53	79,88	1
UNF	-45,48	-45,07	62,88	0

^aLos valores críticos para una χ_p^2 al 95 %, con p=38, 58, 78 , son respectivamente 53,38 , 76,78 y 99,62.

Los resultados cambian notablemente en relación al capítulo anterior. Cuando se estima un VAR(1) sin restringir, sólo en 3 casos se elige el modelo univariante

como el correcto. Ahora, con los modelos periódicos restringidos, para 8 casos de 25, el modelo univariante es el modelo elegido al 95 % de confianza. Las variables seleccionadas son: Abertis, Acerinox, Altadis, Acciona, Ferrovial, Gamesa, Iberia e Indra.

Al tener la posibilidad de restringir los parámetros de los modelos periódicos, se pasa de 3 casos a 8 donde se elige la especificación univariante sobre el modelo periódico. Es decir, se incrementa casi un 170 % los casos donde no se rechaza el contraste de estacionalidad univariante. Aunque el porcentaje se ha incrementado favorablemente a una modelización univariante, todavía hay un gran número de variables para las que el modelo periódico es una forma alternativa de representar la dinámica de las variables.

En la siguiente sección se repite el ejercicio de previsión realizado en el anterior capítulo, para comprobar si la selección de modelos realizada por el contraste elige aquel modelo que mejor prevé.

4.4 Previsiones

En la tabla 4.2 aparecen las previsiones dentro de la muestra, para poder comparar la capacidad predictiva del modelo autorregresivo con el modelo periódico. Igual que en el capítulo anterior, aparecen las medidas de previsión para la serie completa, y para cada uno de los días de la semana. Los índices subrayados son aquellos para los que el contraste selecciona el modelo univariante. En negrita aparece señalado el RECM del modelo que mejor prevé para el global de la serie. Por último, se recuadran los RECM de los días donde el modelo que mejor prevé no es el que mejor lo hace para el global. Todos los RECM están multiplicados por diez mil.

Tabla 4.2: Precisión de las previsiones dentro de la muestra

	RECM			RECM			RECM	
	AR(p)	VEC(p)		AR(p)	VEC(p)		AR(p)	VEC(p)
IBEX	0,628	0,619	<u>ABE</u>	0,950	1,079	ACS	1,027	0,980
l	0,684	0,653	l	0,974	1,127	l	1,279	1,277
m	0,524	0,505	m	0,885	0,987	m	0,963	0,909
x	0,639	0,634	x	0,939	0,984	x	1,031	0,971
j	0,669	0,696	j	0,944	0,948	j	0,970	0,940
v	0,612	0,591	v	1,004	1,308	v	0,839	0,719
<u>ACX</u>	1,128	1,146	<u>ALT</u>	1,039	1,076	<u>ANA</u>	1,272	1,293
l	0,972	0,974	l	1,012	1,068	l	1,096	1,109
m	1,079	1,091	m	0,894	0,951	m	1,250	1,262
x	1,198	1,222	x	1,008	1,054	x	1,317	1,353
j	1,062	1,079	j	1,302	1,325	j	1,389	1,427
v	1,299	1,330	v	0,930	0,939	v	1,288	1,293
BBVA	1,093	0,920	BKT	1,217	1,187	BTO	0,933	0,816
l	1,461	1,180	l	1,103	1,012	l	1,210	0,864
m	0,771	0,783	m	0,936	0,870	m	0,837	0,699
x	0,958	0,834	x	1,261	1,247	x	0,752	0,779
j	0,915	0,929	j	1,617	1,643	j	0,816	0,705
v	1,220	0,816	v	1,052	1,007	v	0,978	0,997
ELE	1,122	1,081	ENG	1,045	0,980	FCC	1,126	1,066
l	1,048	1,014	l	1,003	0,950	l	1,143	1,110
m	1,621	1,561	m	0,904	0,875	m	1,016	0,936
x	0,983	0,935	x	1,028	0,995	x	1,046	1,008
j	0,916	0,884	j	1,251	1,136	j	1,293	1,193
v	0,875	0,846	v	1,007	0,921	v	1,110	1,062
<u>FER</u>	1,228	1,421	<u>GAM</u>	1,426	1,432	GAS	0,991	0,924
l	1,274	1,281	l	1,199	1,214	l	0,830	0,826
m	1,080	1,322	m	1,416	1,433	m	0,880	0,864
x	1,025	1,085	x	1,517	1,523	x	1,239	1,109
j	1,328	1,332	j	1,656	1,685	j	1,075	0,981
v	1,392	1,939	v	1,297	1,364	v	0,869	0,804
IBE	0,960	0,928	<u>IBLA</u>	1,380	1,393	<u>IDR</u>	1,046	1,047
l	0,880	0,845	l	1,200	1,224	l	1,109	1,129
m	1,024	0,995	m	1,161	1,164	m	0,945	0,946
x	1,007	1,108	x	1,742	1,778	x	1,115	1,126
j	0,778	0,782	j	1,233	1,235	j	1,114	1,121
v	1,080	0,876	v	1,477	1,472	v	0,934	0,940

Continúa en la página siguiente

Tabla 4.2: Continuación

	RECM			RECM			RECM	
	AR(p)	VEC(p)		AR(p)	VEC(p)		AR(p)	VEC(p)
ITX	1,167	1,147	MVC	1,889	1,829	POP	0,764	0,722
l	1,066	0,996	l	1,763	1,508	l	0,797	0,695
m	0,989	0,986	m	1,509	1,284	m	0,745	0,709
x	1,320	1,305	x	2,257	2,061	x	0,815	0,792
j	1,390	1,400	j	2,365	2,400	j	0,807	0,748
v	1,012	0,977	v	1,333	1,672	v	0,643	0,657
REP	1,111	1,040	SAN	0,929	0,881	TEF	0,922	0,919
l	1,030	1,080	l	1,131	1,092	l	0,978	0,841
m	1,215	1,084	m	0,778	0,746	m	0,810	0,763
x	0,953	0,888	x	0,885	0,834	x	0,843	0,829
j	1,288	1,209	j	0,930	0,892	j	0,850	0,826
v	1,035	0,903	v	0,884	0,799	v	1,096	1,251
UNF	1,106	1,078						
l	1,271	1,273						
m	1,144	1,075						
x	0,865	0,864						
j	1,159	1,109						
v	1,050	1,029						

Fin de la tabla

De las 8 series cuya modelización es univariante, de acuerdo con el contraste, en los 8 casos, la mejor previsión intramuestral la obtiene el modelo univariante. Además, para estos 8 casos, el modelo periódico no bate al modelo univariante para ninguno de los días. Con lo cual no es posible construir modelos compuestos para estas variables.

En los 17 valores donde se rechaza el contraste, en todos ellos el modelo periódico genera previsiones más precisas que el modelo univariante. Sin embargo, para estos 17 casos, no siempre el modelo periódico es el que mejor prevé todos los días. De hecho, sólo en 6 de los 17 casos, el modelo periódico se comporta mejor para todos los días. Estos índices son: ACS, Endesa, Enagas, FCC, Gas Natural y Santander.

En la tabla 4.3 se comprueba si las anteriores pautas se trasladan a las previsiones fuera de la muestra.

Tabla 4.3: Precisión de las previsiones fuera de la muestra

	RECM			RECM			RECM	
	AR(p)	VEC(p)		AR(p)	VEC(p)		AR(p)	VEC(p)
IBEX	0,827	0,826	<u>ABE</u>	0,919	1,015	ACS	1,113	1,167
l	0,731	0,738	l	0,960	0,962	l	0,927	0,916
m	0,667	0,584	m	0,652	0,623	m	0,806	0,883
x	1,067	1,047	x	0,900	1,038	x	1,511	1,580
j	0,823	0,835	j	0,989	1,063	j	1,166	1,235
v	0,790	0,857	v	1,045	1,276	v	1,020	1,081
<u>ACX</u>	1,592	1,629	<u>ALT</u>	1,812	2,196	<u>ANA</u>	2,033	2,086
l	1,436	1,518	l	1,001	0,973	l	2,000	1,949
m	0,845	0,778	m	0,728	2,655	m	1,884	1,976
x	1,778	1,946	x	0,644	0,797	x	2,371	2,430
j	1,897	1,850	j	3,536	3,592	j	2,034	2,178
v	1,772	1,773	v	1,402	1,603	v	1,835	1,846
BBVA	1,173	1,220	BKT	1,371	1,396	BTO	1,078	1,066
l	0,960	0,938	l	1,114	1,039	l	1,410	1,188
m	1,004	1,087	m	1,241	1,341	m	0,940	0,847
x	1,293	1,375	x	1,815	1,771	x	1,265	1,309
j	0,903	1,265	j	1,325	1,494	j	0,812	0,814
v	1,570	1,375	v	1,251	1,224	v	0,820	1,087
ELE	0,694	0,689	ENG	1,196	1,339	FCC	1,401	1,368
l	0,698	0,621	l	1,208	1,327	l	1,105	1,184
m	0,733	0,612	m	0,769	0,904	m	0,853	0,862
x	0,678	0,680	x	1,541	1,387	x	2,055	1,994
j	0,695	0,749	j	1,158	1,639	j	1,347	1,131
v	0,662	0,766	v	1,177	1,331	v	1,351	1,398
<u>FER</u>	1,321	1,604	<u>GAM</u>	1,774	1,792	GAS	1,397	1,437
l	1,420	1,356	l	1,739	1,723	l	1,024	1,063
m	1,075	1,215	m	1,336	1,421	m	1,786	1,726
x	1,493	1,699	x	2,001	2,007	x	1,457	1,619
j	1,236	1,345	j	1,941	1,938	j	1,373	1,365
v	1,341	2,203	v	1,779	1,811	v	1,229	1,316
IBE	1,373	1,526	<u>IBLA</u>	1,650	1,655	<u>IDR</u>	1,036	1,046
l	1,020	1,047	l	1,242	1,255	l	0,821	0,821
m	1,161	1,266	m	2,111	2,110	m	1,248	1,237
x	1,698	2,106	x	1,878	1,930	x	0,863	0,906
j	1,349	1,695	j	1,246	1,189	j	1,065	1,064
v	1,529	1,278	v	1,592	1,591	v	1,123	1,147

Continúa en la página siguiente

Tabla 4.3: Continuación

	RECM			RECM			RECM	
	AR(p)	VEC(p)		AR(p)	VEC(p)		AR(p)	VEC(p)
ITX	1,158	1,163	MVC	1,657	1,770	POP	1,121	1,069
l	1,213	1,216	l	1,553	1,676	l	1,048	1,037
m	1,128	1,197	m	2,489	2,340	m	0,978	0,926
x	1,215	1,173	x	1,238	1,042	x	1,579	1,440
j	1,097	1,256	j	1,156	1,590	j	1,053	0,934
v	1,132	0,948	v	1,501	1,943	v	0,794	0,915
REP	1,453	1,362	SAN	1,018	1,149	TEF	0,931	0,940
l	0,861	1,039	l	0,901	1,092	l	0,820	0,875
m	1,050	0,864	m	0,864	0,868	m	0,698	0,667
x	1,471	1,225	x	1,228	1,280	x	1,210	1,192
j	1,473	1,239	j	0,867	0,852	j	0,884	0,888
v	2,093	2,100	v	1,167	1,514	v	0,938	1,000
UNF	1,378	1,375						
l	0,918	0,989						
m	1,607	1,626						
x	1,563	1,497						
j	1,393	1,467						
v	1,298	1,197						

Fin de la tabla

Fuera de la muestra, los modelos univariantes son los que mejor prevén en los 8 casos en los que fueron seleccionados por el contraste.

En 7 de los 17 casos restantes, el modelo periódico tiene mejores resultados que el modelo univariante. En el anterior capítulo, en sólo 2 casos el modelo periódico conseguía las mejores previsiones. Esto es un incremento importante, pero se considera que todavía no es suficiente mejora.

Estos 7 casos son: Ibex-35, Banesto, Endesa, FCC, Banco Popular, Repsol y Unión Fenosa. Dentro de éstos se encuentran los dos únicos casos para los que el modelo periódico tenía mejores resultados en el anterior capítulo, que eran FCC y Repsol.

En estos 7 casos, el contraste de estacionalidad univariante fue rechazado para el 95 % de confianza.

Se comprueba si se pueden construir modelos compuestos. Igual que en el anterior capítulo, se comprueba qué modelo prevé mejor para cada uno de los días dentro de la muestra, y se usa esos modelos para calcular las previsiones fuera de la muestra. Los resultados de los modelos compuestos contruídos aparecen en la tabla 4.4.

Tabla 4.4: Precisión de las previsiones modelos compuestos

	RECM		
	AR(p)	VEC(p)	Compuesto
IBEX	0,827	0,826	0,824
BBVA	1,173	1,220	1,139
BKT	1,371	1,396	1,361
BTO	1,078	1,066	1,006
IBE	1,373	1,526	1,344
ITX	1,158	1,163	1,131
MVC	1,657	1,770	1,610
POP	1,121	1,069	1,050
REP	1,453	1,362	1,337
TEF	0,931	0,940	0,927
UNF	1,378	1,375	1,365

Los resultados no podrían ser mejores. Para todas las series para las que se ha construído un modelo compuesto, este modelo compuesto es el más preciso a la hora de prever.

Se aplica el contraste de igualdad de precisión en las previsiones de Diebold y Mariano (1995). Los resultados se muestran en la tabla 4.5:

Igual que en el anterior capítulo se usan los valores críticos de McCracken (2007). Debajo del valor del estadístico aparece el valor crítico al 95 % obtenido por McCracken. Los modelos cuyas previsiones son iguales, según el contraste, aparecen señaladas con un asterisco.

La tabla 4.5 indica que en 3 de los 11 casos, el modelo compuesto no da previsiones estadísticamente diferentes a las obtenidas por los otros modelos. Estos casos son : IBEX-35, Bankinter e Inditex.

Tabla 4.5: Contraste de Diebold-Mariano

IBEX	VEC(p)	Compuesto	BBVA	VEC(p)	Compuesto
AR(p)	0,496* (1,281)	0,735* (1,342)	AR(p)	1,154 (1,007)	
VEC(p)			VEC(p)		1,535 (1,064)
BKT	VEC(p)	Compuesto	BTO	VEC(p)	Compuesto
AR(p)	0,328* (1,342)	0,288* (1,416)	AR(p)	0,877* (1,007)	1,550 (1,064)
IBE	VEC(p)	Compuesto	ITX	VEC(p)	Compuesto
AR(p)	1,624 (1,007)		AR(p)	0,701* (1,064)	0,893* (1,122)
VEC(p)		1,702 (1,031)	VEC(p)		
MVC	VEC(p)	Compuesto	POP	VEC(p)	Compuesto
AR(p)	1,091 (1,007)		AR(p)	1,849 (1,007)	
VEC(p)		1,702 (1,122)	VEC(p)		1,306 (1,064)
REP	VEC(p)	Compuesto	TEF	VEC(p)	Compuesto
AR(p)	1,220 (1,007)		AR(p)	1,100 (1,007)	
VEC(p)		1,195 (1,064)	VEC(p)		1,349 (1,031)
UNF	VEC(p)	Compuesto			
AR(p)	0,179* (1,086)	0,365* (1,122)			

4.5 Conclusiones

En este capítulo se construyen, para las 25 series objeto de estudio, un modelo periódico de corrección del error. Este modelo se ha restringido eliminando los parámetros no significativos. Los modelos univariantes estimados son los mismos del capítulo anterior.

Los resultados obtenidos han sido importantes por varias razones. Cuando se estima un VEC, y este se restringe de una manera apropiada, el contraste de estacionalidad univariante desarrollado por Flores y Novales (1997), ha demostrado ser una herramienta que puede seleccionar aquel modelo que mejor prevé. Se ha obtenido que en el 100 % de los casos considerados, cuando el contraste selecciona el modelo univariante, este modelo es el que obtiene mejores previsiones tanto dentro de la

muestra como fuera de la muestra. Además, el modelo univariante prevé mejor dentro de la muestra para todos los días de la semana, imposibilitando la construcción de un modelo compuesto.

El otro resultado importante es la posibilidad de construir modelos compuestos que mejoran las previsiones. En el capítulo anterior, sólo en 2 casos (BBVA y Repsol) de los 8 donde se pudo construir un modelo compuesto, éste fue el que mejores previsiones realizó.

En este capítulo se han podido construir 11 modelos compuestos frente a los 8 de antes, un incremento del 37,5 %. Además en los 11 casos, el modelo compuesto ha sido el que mejores previsiones ha generado.

4.A Apéndice: Estimación modelos VEC

Para todos los valores se comprueba si existen las cuatro relaciones de cointegración que aparecen en Franses y Romijn (1993) y que permiten escribir el VECM, cuando la serie original diaria es $I(1)$:

$$\begin{aligned} ecm1_t &= v_t - j_t \\ ecm2_t &= j_t - x_t \\ ecm3_t &= x_t - m_t \\ ecm4_t &= m_t - l_t \end{aligned} \tag{4.1}$$

Para comprobarlo, para todas las series, se usa el método de Engle y Granger (1987), y se presenta

4.A.1 IBEX-35

4.A.1.1 Relaciones de cointegración

En la tabla 4.6 se presenta el test ADF que muestra, efectivamente, la presencia de las cuatro relaciones de cointegración, según el método de Engle y Granger

(1987).

Tabla 4.6: IBEX-35: Test de cointegración, método de Engle-Granger

Variable dependiente	$p = 0$
$ecm1_t$	-10,35
$ecm2_t$	-11,81
$ecm3_t$	-10,76
$ecm4_t$	-12,95

Valor crítico(95 %):-5,28

(Phillips y Ouliaris (1990)).

Los gráficos de los residuos de estas relaciones de cointegración se presentan en el gráfico 4.1 , y en ellos se observa el carácter estacionario de éstas.

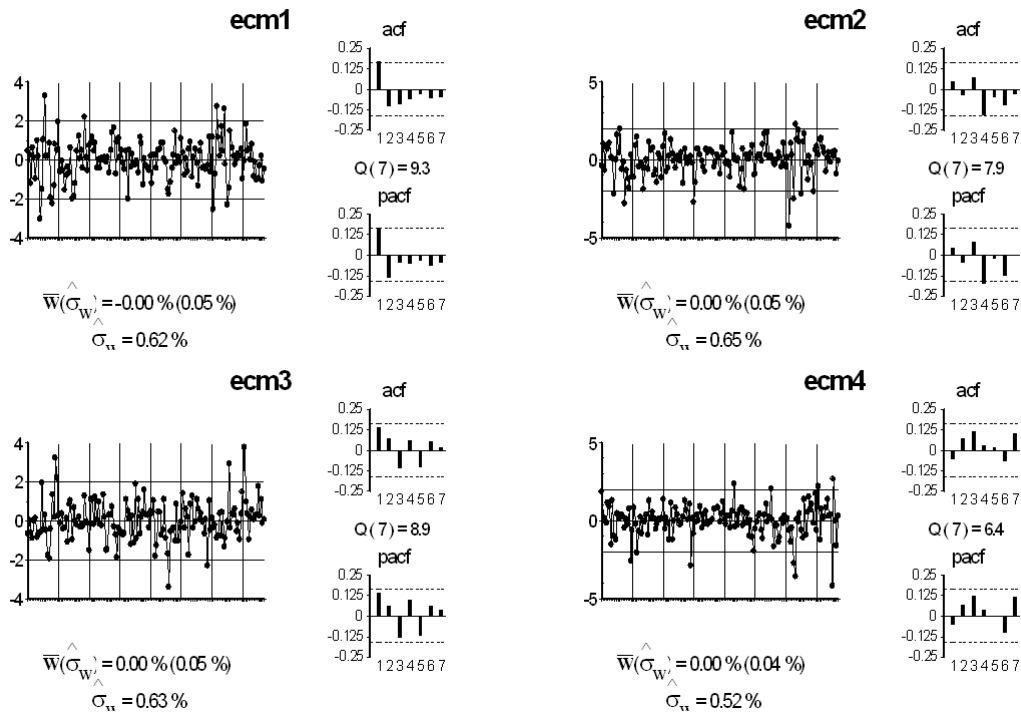


Gráfico 4.1: IBEX-35: Relaciones de cointegración

4.A.1.2 Estimación modelo VEC

Se estiman todos los parámetros de forma conjunta por mínimos cuadrados generalizados, salvo los de las relaciones de cointegración, que se restringen. Los resultados aparecen en la tabla 4.7.

Tabla 4.7: IBEX-35: Estimación del VEC(0)

Variable dependiente	Ecuaciones ^a				
	∇l_t	∇m_t	∇x_t	∇j_t	∇v_t
μ			0,002 (0,001)	0,002 (0,001)	0,003 (0,001)
$ecm1_{t-1}$	1,31 (0,09)	1,36 (0,11)	1,25 (0,13)	1,31 (0,17)	0,48 (0,19)
$ecm2_{t-1}$	0,97 (0,07)	1,04 (0,08)	0,98 (0,06)		
$ecm3_{t-1}$	0,87 (0,06)	0,88 (0,06)			
$ecm4_{t-1}$	1,13 (0,06)				

^aLa tabla muestra los coeficientes estimados del modelo VEC donde cada columna representa una ecuación del mismo. Entre paréntesis se presentan las desviaciones típicas.

La matriz de covarianzas se presenta en (4.2).

$$\Sigma_u = \begin{pmatrix} 4,30E-05 & 4,63E-05 & 4,18E-05 & 4,63E-05 & 4,65E-05 \\ 4,63E-05 & 7,59E-05 & 7,36E-05 & 8,01E-05 & 7,93E-05 \\ 4,18E-05 & 7,36E-05 & 1,10E-04 & 1,18E-04 & 1,17E-04 \\ 4,63E-05 & 8,01E-05 & 1,18E-04 & 1,68E-04 & 1,78E-04 \\ 4,65E-05 & 7,93E-05 & 1,17E-04 & 1,78E-04 & 2,26E-04 \end{pmatrix} \quad (4.2)$$

El gráfico 4.2 muestra los residuos del VEC(0). Por otro lado, en la tabla 4.8 se presentan las funciones de correlación cruzadas. En ninguna de ellas se aprecian correlaciones significativas, por lo cual, el modelo de la tabla 4.7 representa de forma adecuada la correlación dinámica entre las variables.

Tabla 4.8: IBEX-35: Función de correlación cruzada residual del VEC(0)

Retardos	r_{11}	r_{12}	r_{13}	r_{14}	r_{15}
1	-0,016	0,041	0,062	0,066	0,070
2	0,035	-0,011	-0,057	-0,006	-0,061
3	-0,009	0,059	0,066	0,069	0,049
4	-0,033	-0,034	0,012	0,010	0,035
5	-0,014	-0,009	0,077	0,077	0,073
	r_{21}	r_{22}	r_{23}	r_{24}	r_{25}
1	-0,009	0,062	0,076	0,081	0,085
2	0,063	0,049	-0,001	0,027	-0,047
3	0,008	0,099	0,091	0,102	0,070
4	-0,054	-0,029	0,034	0,079	0,095
5	-0,048	-0,033	0,020	0,046	0,055
	r_{31}	r_{32}	r_{33}	r_{34}	r_{35}
1	-0,088	-0,006	0,019	0,038	0,046
2	0,011	0,030	0,015	0,048	-0,019
3	0,018	0,090	0,046	0,021	-0,038
4	-0,046	0,003	0,086	0,126	0,132
5	-0,067	-0,065	-0,057	-0,010	0,021
	r_{41}	r_{42}	r_{43}	r_{44}	r_{45}
1	-0,114	-0,035	0,029	0,048	0,058
2	-0,057	-0,043	-0,018	0,001	-0,089
3	0,042	0,069	0,041	0,039	0,025
4	-0,135	-0,074	0,012	0,017	0,025
5	-0,082	-0,073	-0,044	-0,017	0,005
	r_{51}	r_{52}	r_{53}	r_{54}	r_{55}
1	-0,154	-0,096	-0,013	0,007	0,025
2	-0,046	-0,052	0,021	0,041	-0,063
3	0,003	0,035	-0,002	-0,031	-0,045
4	-0,122	-0,053	-0,007	-0,008	-0,005
5	-0,070	-0,049	-0,032	-0,014	0,003

DT= $\frac{2}{\sqrt{T}}$ = 0,161. En * significativos al 95 %.

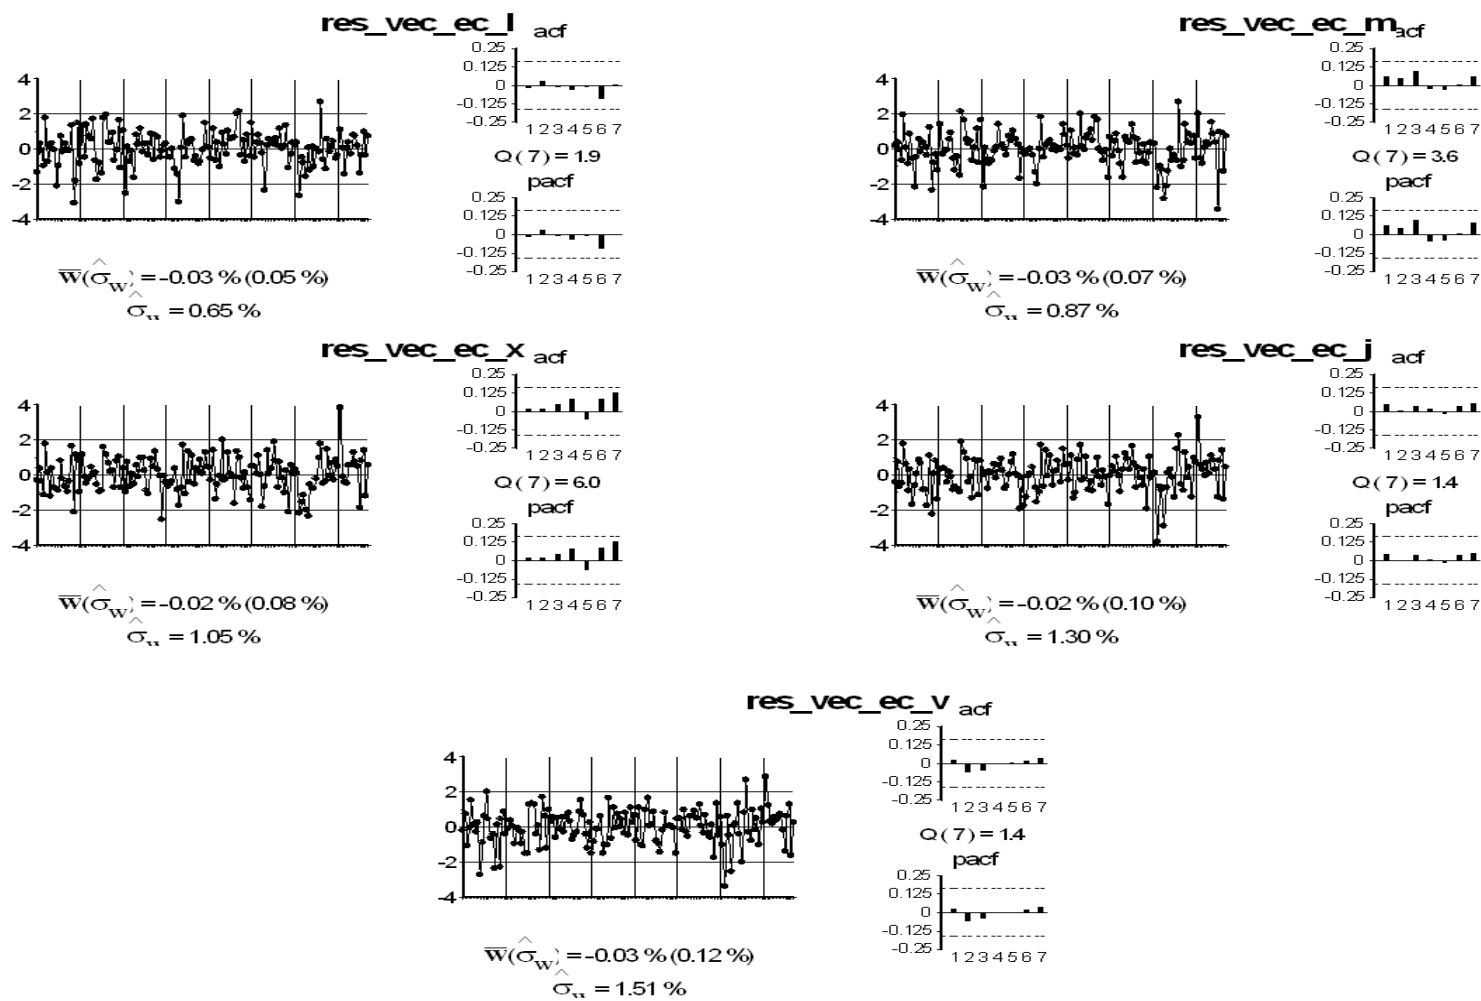


Gráfico 4.2: IBEX-35: Residuos del VEC(0)

La forma correcta de mostrar el modelo periódico es a través del VEC ortogonalizado. A través de la matriz 4.2, se puede obtener la matriz A_0 con la que se ortogonaliza el modelo:

$$A_0 = \begin{pmatrix} 1 & 0 & 0 & 0 & 0 \\ -1,08 & 1 & 0 & 0 & 0 \\ 0,21 & -1,10 & 1 & 0 & 0 \\ -0,05 & -0,01 & -1,05 & 1 & 0 \\ -0,02 & 0,02 & 0,31 & -1,28 & 1 \end{pmatrix} \quad (4.3)$$

Premultiplicando el modelo de la tabla 4.7 por la matriz 4.3 se obtiene el modelo ortogonalizado que representa el modelo periódico, que aparece en la tabla 4.9.

Tabla 4.9: IBEX-35: Modelo VEC(0) ortogonalizado

Variable dependiente	Ecuaciones				
	∇l_t	∇m_t	∇x_t	∇j_t	∇v_t
μ			0,0020	-0,0001	0,0011
$ecm1_{t-1}$	1,31	-0,054	0,037	-0,079	-0,80
$ecm2_{t-1}$	0,97	-0,0069	0,047	-1,09	0,31
$ecm3_{t-1}$	0,87	-0,060	-0,78	-0,051	-0,0005
$ecm4_{t-1}$	1,13	-1,21	0,24	-0,060	-0,027
∇l_t		1,08	-0,21	0,053	0,024
∇m_t			1,10	0,0057	-0,023
∇x_t				1,05	0,31
∇j_t					1,28

4.A.2 Abertis

4.A.2.1 Relaciones de cointegración

La existencia de las cuatro relaciones de cointegración se muestra en la tabla 4.10.

Tabla 4.10: Abertis: Test de cointegración, método de Engle-Granger

Variable dependiente	$p = 0$
$ecm1_t$	-10,92
$ecm2_t$	-12,24
$ecm3_t$	-12,70
$ecm4_t$	-13,54

Valor crítico(95 %):-5,28
(Phillips y Ouliaris (1990)).

Los gráficos de los residuos de estas relaciones de cointegración se presentan en el gráfico 4.3 , y en ellos se observa el carácter estacionario de éstas.

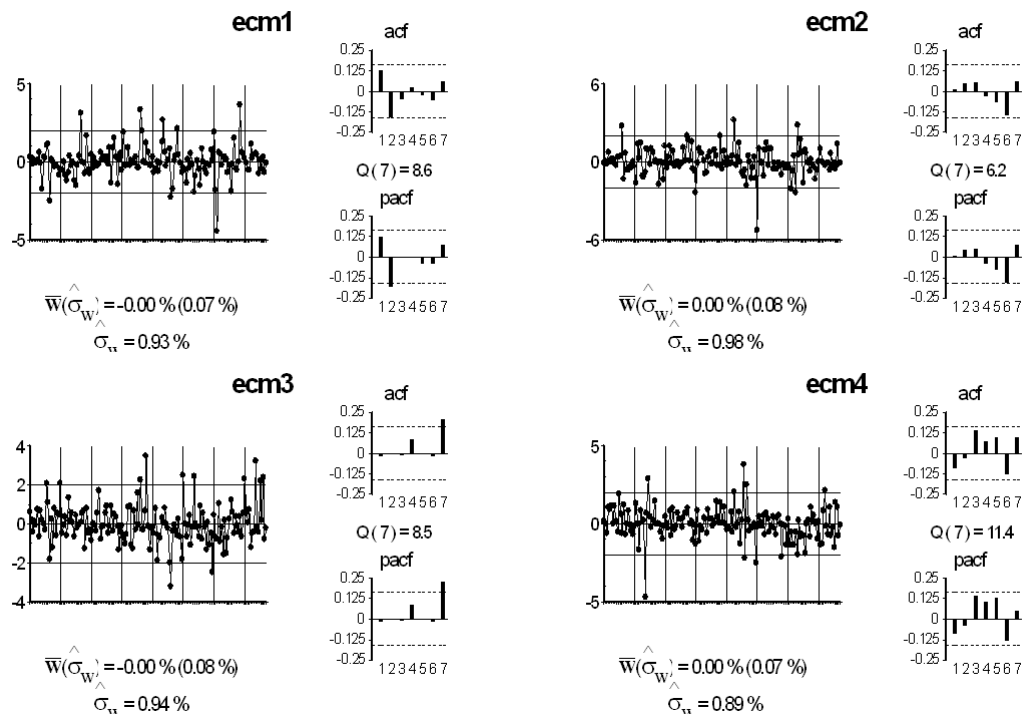


Gráfico 4.3: Abertis: Relaciones de cointegración

4.A.2.2 Estimación modelo VEC

Los parámetros se estiman de forma conjunta por mínimos cuadrados generalizados, salvo las relaciones de cointegración anteriores, que se restringen. Los

resultados aparecen en la tabla 4.11.

Tabla 4.11: Abertis: Estimación del VEC(1)

Variable dependiente	Ecuaciones ^a				
	∇l_t	∇m_t	∇x_t	∇j_t	∇v_t
μ	0,001 (0,001)	0,002 (0,001)	0,003 (0,001)	0,003 (0,002)	0,004 (0,002)
$ecm1_{t-1}$	1,29 (0,11)	1,44 (0,16)	1,45 (0,20)	1,48 (0,24)	0,39 (0,29)
$ecm2_{t-1}$	1,17 (0,11)	1,42 (0,15)	1,53 (0,19)	0,59 (0,23)	0,45 (0,28)
$ecm3_{t-1}$	1,01 (0,11)	1,20 (0,16)	0,28 (0,20)	0,55 (0,24)	0,50 (0,29)
$ecm4_{t-1}$	1,13 (0,12)	0,18 (0,17)	0,20 (0,21)	0,38 (0,26)	0,34 (0,31)
∇j_{t-1}				-0,20 (0,08)	
∇v_{t-1}	-0,19 (0,08)	-0,34 (0,11)	-0,42 (0,14)	-0,48 (0,16)	-0,22 (0,21)

^aLa tabla muestra los coeficientes estimados del modelo VEC donde cada columna representa una ecuación del mismo. Entre paréntesis se presentan las desviaciones típicas.

La matriz de covarianzas se presenta en (4.4).

$$\Sigma_u = \begin{pmatrix} 8,82E-05 & 9,27E-05 & 9,30E-05 & 9,43E-05 & 9,43E-05 \\ 9,27E-05 & 1,72E-04 & 1,77E-04 & 1,88E-04 & 2,02E-04 \\ 9,30E-05 & 1,77E-04 & 2,70E-04 & 2,84E-04 & 3,13E-04 \\ 9,43E-05 & 1,88E-04 & 2,84E-04 & 3,89E-04 & 4,36E-04 \\ 9,43E-05 & 2,02E-04 & 3,13E-04 & 4,36E-04 & 5,64E-04 \end{pmatrix} \quad (4.4)$$

Los residuos del VEC(1) aparecen en el gráfico 4.4. Por otro lado, en la tabla 4.12 se presentan las funciones de autocorrelación cruzadas. Sólo se aprecian dos correlaciones cruzadas significativa al 95 %, ambas en un tercer retardo, por lo que se considera que el modelo de la tabla 4.11 representa de forma adecuada la correlación dinámica entre las variables.

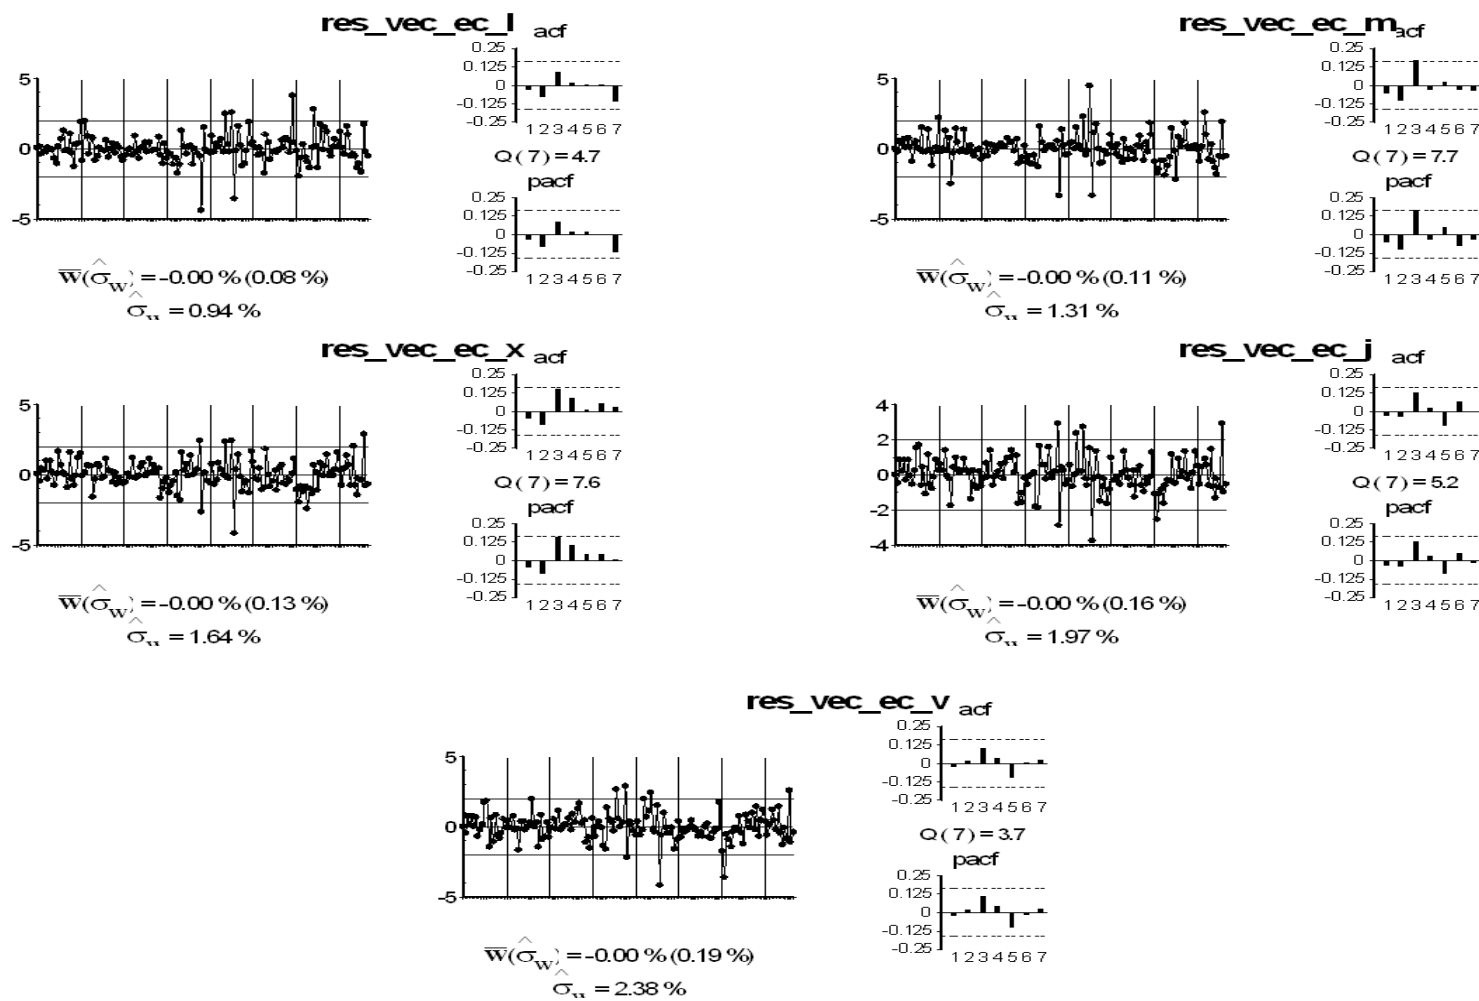


Gráfico 4.4: Abertis: Residuos del VEC(1)

Tabla 4.12: Abertis: Función de correlación cruzada residual del VEC(1)

Retardos	r_{11}	r_{12}	r_{13}	r_{14}	r_{15}
1	-0,036	-0,041	-0,040	-0,027	-0,026
2	-0,082	-0,095	-0,105	-0,075	-0,048
3	0,092	0,081	0,052	0,096	0,049
4	0,018	-0,048	-0,036	-0,047	-0,042
5	0,005	-0,027	0,005	-0,022	-0,045
	r_{21}	r_{22}	r_{23}	r_{24}	r_{25}
1	-0,041	-0,052	-0,051	-0,035	-0,028
2	-0,086	-0,104	-0,106	-0,060	-0,034
3	0,155	0,173*	0,147	0,148	0,105
4	-0,048	-0,035	0,058	0,033	0,038
5	0,038	0,024	0,068	0,035	0,026
	r_{31}	r_{32}	r_{33}	r_{34}	r_{35}
1	-0,036	-0,047	-0,045	-0,029	-0,022
2	-0,070	-0,086	-0,090	-0,032	0,007
3	0,087	0,184*	0,157	0,157	0,116
4	-0,035	0,001	0,093	0,049	0,083
5	-0,038	-0,041	0,008	-0,014	-0,035
	r_{41}	r_{42}	r_{43}	r_{44}	r_{45}
1	-0,035	-0,047	-0,045	-0,032	-0,021
2	-0,101	-0,101	-0,099	-0,041	-0,016
3	0,046	0,135	0,118	0,124	0,103
4	-0,047	-0,019	0,069	0,025	0,023
5	-0,095	-0,124	-0,073	-0,095	-0,119
	r_{51}	r_{52}	r_{53}	r_{54}	r_{55}
1	-0,029	-0,047	-0,045	-0,037	-0,024
2	-0,115	-0,087	-0,074	-0,001	0,016
3	0,005	0,126	0,125	0,124	0,103
4	-0,013	0,029	0,067	0,047	0,041
5	-0,063	-0,081	-0,033	-0,071	-0,096

DT = $\frac{2}{\sqrt{T}} = 0,161$. En * significativos al 95 %.

Para representar un modelo periódico, lo correcto es hacerlo con un VEC ortogonalizado. Para obtener la matriz A_0 con la que se ortogonaliza el modelo, se utiliza la matriz 4.4.

$$A_0 = \begin{pmatrix} 1 & 0 & 0 & 0 & 0 \\ -1,04 & 1 & 0 & 0 & 0 \\ 0,07 & -1,09 & 1 & 0 & 0 \\ 0,11 & -0,09 & -1,03 & 1 & 0 \\ 0,15 & 0,01 & 0,01 & -1,17 & 1 \end{pmatrix} \quad (4.5)$$

Premultiplicando el modelo de la tabla 4.11 por la matriz 4.5 se obtiene el modelo ortogonalizado que representa el modelo periódico, que se muestra en la tabla 4.13.

Tabla 4.13: Abertis: Modelo VEC(1) ortogonalizado

Variable dependiente	Ecuaciones				
	∇l_t	∇m_t	∇x_t	∇j_t	∇v_t
μ	0,0010	0,0010	0,0010	-0,0001	0,0007
$ecm1_{t-1}$	1,29	0,089	0,027	-0,012	-1,11
$ecm2_{t-1}$	0,17	0,21	0,11	-1,00	-0,016
$ecm3_{t-1}$	1,01	0,14	-0,92	0,26	0,036
$ecm4_{t-1}$	1,13	-0,99	0,09	0,28	0,063
∇l_t		1,04	-0,071	-0,11	-0,15
∇m_t			1,06	0,094	-0,012
∇x_t				1,03	-0,014
∇j_t					1,17
∇j_{t-1}					-0,20
∇v_{t-1}	-0,19	-0,14	-0,080	-0,032	0,30

4.A.3 ACS

4.A.3.1 Relaciones de cointegración

La existencia de las relaciones de cointegración se muestra en la tabla 4.14.

Tabla 4.14: ACS: Test de cointegración, método de Engle-Granger

Variable dependiente	$p = 0$
$ecm1_t$	-13,20
$ecm2_t$	-12,77
$ecm3_t$	-12,13
$ecm4_t$	-13,26

Valor crítico(95 %):-5,28
(Phillips y Ouliaris (1990)).

Los gráficos de los residuos de estas relaciones de cointegración se presentan en el gráfico 4.5, y en ellos se observa el carácter estacionario de éstas.

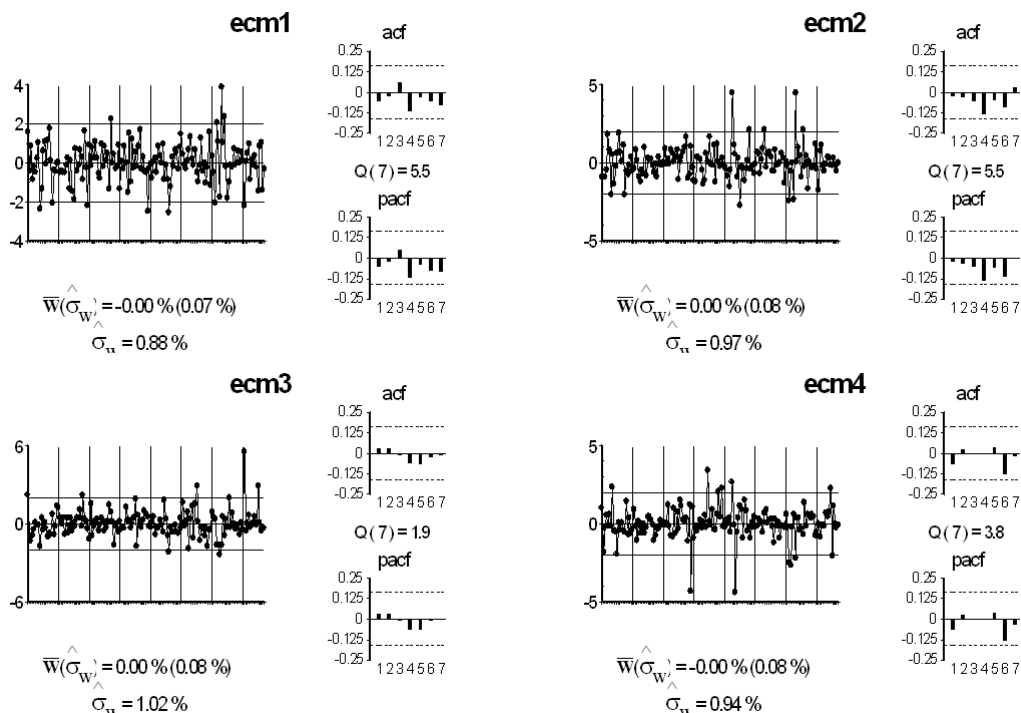


Gráfico 4.5: ACS: Relaciones de cointegración

4.A.3.2 Estimación modelo VEC

Los parámetros se estiman de forma conjunta por mínimos cuadrados generalizados, salvo los de las relaciones de cointegración que se han restringido. Los resultados aparecen en la tabla 4.15.

Tabla 4.15: ACS: Estimación del VEC(2)

Variable dependiente	Ecuaciones ^a				
	∇l_t	∇m_t	∇x_t	∇j_t	∇v_t
μ				0,002 (0,001)	0,003 (0,001)
$ecm1_{t-1}$	1,21 (0,13)	1,40 (0,17)	1,40 (0,18)	1,46 (0,22)	0,48 (0,24)
$ecm2_{t-1}$	1,01 (0,10)	1,12 (0,13)	1,08 (0,09)		0,45 (0,13)
$ecm3_{t-1}$	1,06 (0,09)	1,19 (0,11)	0,18 (0,07)		
$ecm4_{t-1}$	1,11 (0,13)	0,19 (0,12)			
∇l_{t-1}	0,20 (0,10)	0,34 (0,09)	0,10 (0,06)	0,06 (0,04)	
∇m_{t-1}	-0,18 (0,10)	-0,21 (0,09)			
∇x_{t-1}					0,28 (0,09)
∇j_{t-1}				0,22 (0,09)	
∇v_{t-1}		-0,11 (0,07)		-0,13 (0,10)	-0,29 (0,12)
∇x_{t-2}	-0,053 (0,041)	-0,028 (0,052)	-0,082 (0,068)	-0,14 (0,05)	
∇j_{t-2}			0,21 (0,10)	0,51 (0,13)	0,37 (0,14)
∇v_{t-2}		-0,15 (0,06)	-0,16 (0,10)	-0,40 (0,13)	-0,41 (0,15)

^aLa tabla muestra los coeficientes estimados del modelo VEC donde cada columna representa una ecuación del mismo. Entre paréntesis se presentan las desviaciones típicas.

La matriz de covarianzas se presenta en (4.6).

$$\Sigma_u = \begin{pmatrix} 1,63E-04 & 1,66E-04 & 1,56E-04 & 1,49E-04 & 1,51E-04 \\ 1,66E-04 & 2,51E-04 & 2,52E-04 & 2,44E-04 & 2,43E-04 \\ 1,56E-04 & 2,52E-04 & 3,50E-04 & 3,46E-04 & 3,32E-04 \\ 1,49E-04 & 2,44E-04 & 3,46E-04 & 4,31E-04 & 4,54E-04 \\ 1,51E-04 & 2,43E-04 & 3,32E-04 & 4,54E-04 & 5,46E-04 \end{pmatrix} \quad (4.6)$$

Los residuos del VEC(2) aparecen en el gráfico 4.6. Por su parte, en la tabla 4.16 se muestran las funciones de correlación cruzadas. Hay que señalar que seis correlaciones son estadísticamente distintas de 0, todas ellas en el retardo 4, pero no se cree necesario incrementar el orden del VEC(2), por lo que se considera que el modelo de la tabla 4.15 representa de forma adecuada la relación existente entre las variables.

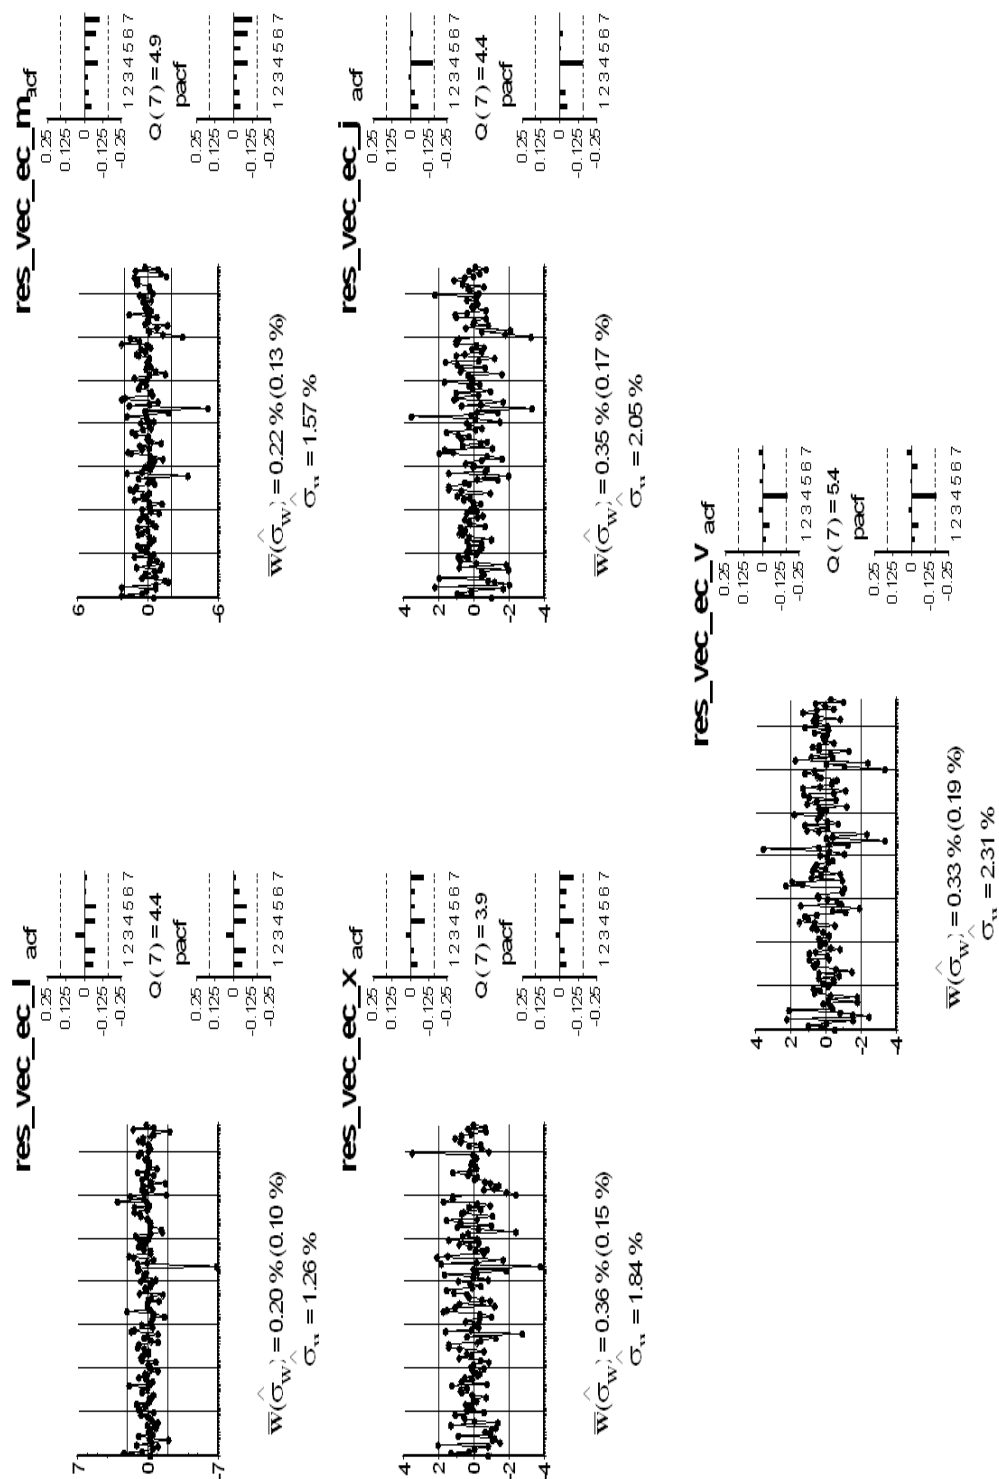


Gráfico 4.6: ACS: Residuos del VEC(2)

Tabla 4.16: ACS: Función de correlación cruzada residual del VEC(2)

Retardos	r_{11}	r_{12}	r_{13}	r_{14}	r_{15}
1	-0,062	-0,036	-0,046	-0,049	-0,046
2	-0,076	-0,043	-0,012	-0,008	-0,022
3	0,065	0,040	0,028	0,012	-0,007
4	-0,080	-0,118	-0,085	-0,169*	-0,202*
5	-0,084	-0,003	0,020	0,021	0,014
	r_{21}	r_{22}	r_{23}	r_{24}	r_{25}
1	-0,061	-0,044	-0,032	-0,027	-0,027
2	-0,075	-0,036	-0,008	-0,013	-0,034
3	-0,016	-0,025	-0,025	-0,067	-0,066
4	-0,072	-0,090	-0,065	-0,105	-0,162*
5	-0,114	-0,037	0,006	0,033	0,049
	r_{31}	r_{32}	r_{33}	r_{34}	r_{35}
1	-0,066	-0,042	-0,049	-0,056	-0,058
2	-0,085	-0,043	-0,027	-0,036	-0,059
3	0,016	0,029	0,031	-0,016	-0,033
4	-0,131	-0,102	-0,097	-0,117	-0,143
5	-0,149	-0,073	-0,030	0,043	0,070
	r_{41}	r_{42}	r_{43}	r_{44}	r_{45}
1	-0,060	-0,035	-0,041	-0,051	-0,048
2	-0,071	-0,016	-0,005	-0,034	-0,055
3	0,037	0,069	0,061	0,009	-0,011
4	-0,162*	-0,138	-0,124	-0,153	-0,173*
5	-0,141	-0,096	-0,048	0,005	0,057
	r_{51}	r_{52}	r_{53}	r_{54}	r_{55}
1	-0,044	-0,023	-0,025	-0,033	-0,028
2	-0,048	0,000	0,000	-0,029	-0,045
3	0,095	0,113	0,097	0,041	0,022
4	-0,113	-0,105	-0,090	-0,138	-0,171*
5	-0,155	-0,107	-0,054	-0,021	0,022

DT = $\frac{2}{\sqrt{T}} = 0,162$. En * significativos al 95 %.

Para representar correctamente un modelo periódico, es necesario hacerlo con un VEC ortogonalizado. Para obtener la matriz A_0 con la que se ortogonaliza el modelo, se utiliza la matriz 4.6.

$$A_0 = \begin{pmatrix} 1 & 0 & 0 & 0 & 0 \\ -1,02 & 1 & 0 & 0 & 0 \\ 0,20 & -1,13 & 1 & 0 & 0 \\ 0,02 & 0,06 & -1,04 & 1 & 0 \\ -0,02 & -0,14 & 0,57 & -1,43 & 1 \end{pmatrix} \quad (4.7)$$

Premultiplicando el modelo de la tabla 4.15 por la matriz 4.7 se obtiene el modelo ortogonalizado que representa el modelo periódico, el cual aparece en la tabla 4.17.

Tabla 4.17: ACS: Modelo VEC(2) ortogonalizado

Variable dependiente	Ecuaciones				
	∇l_t	∇m_t	∇x_t	∇j_t	∇v_t
μ				0,0020	0,0001
$ecm1_{t-1}$	1,21	0,17	0,047	0,11	-1,03
$ecm2_{t-1}$	1,01	0,097	0,014	-1,05	0,90
$ecm3_{t-1}$	1,06	0,11	-0,96	-0,095	-0,093
$ecm4_{t-1}$	1,11	-0,94	0,0069	0,033	-0,053
∇l_t		1,02	-0,20	-0,020	0,023
∇m_t			1,13	-0,058	0,14
∇x_t				1,04	-0,58
∇j_t					1,43
∇l_{t-1}	0,20	0,13	-0,25	-0,012	-0,089
∇m_{t-1}	-0,18	-0,028	0,20	-0,016	0,035
∇x_{t-1}					0,28
∇j_{t-1}				0,22	-0,14
∇v_{t-1}		-0,11	0,12		
∇x_{t-2}	-0,053	0,026	-0,061	-0,062	0,16
∇j_{t-2}			0,21	0,29	-0,23
∇v_{t-2}		-0,14	-0,0065	-0,24	0,087

4.A.4 Acerinox

4.A.4.1 Relaciones de cointegración

La existencia de las cuatro relaciones de cointegración se muestra en la tabla 4.18.

Tabla 4.18: Acerinox: Test de cointegración, método de Engle-Granger

Variable dependiente	$p = 0$
$ecm1_t$	-11,96
$ecm2_t$	-13,89
$ecm3_t$	-11,46
$ecm4_t$	-11,29

Valor crítico(95 %):-5,28
(Phillips y Ouliaris (1990)).

Los gráficos de los residuos de estas relaciones de cointegración se presentan en el gráfico 4.7 , y en ellos se observa el carácter estacionario de éstas.

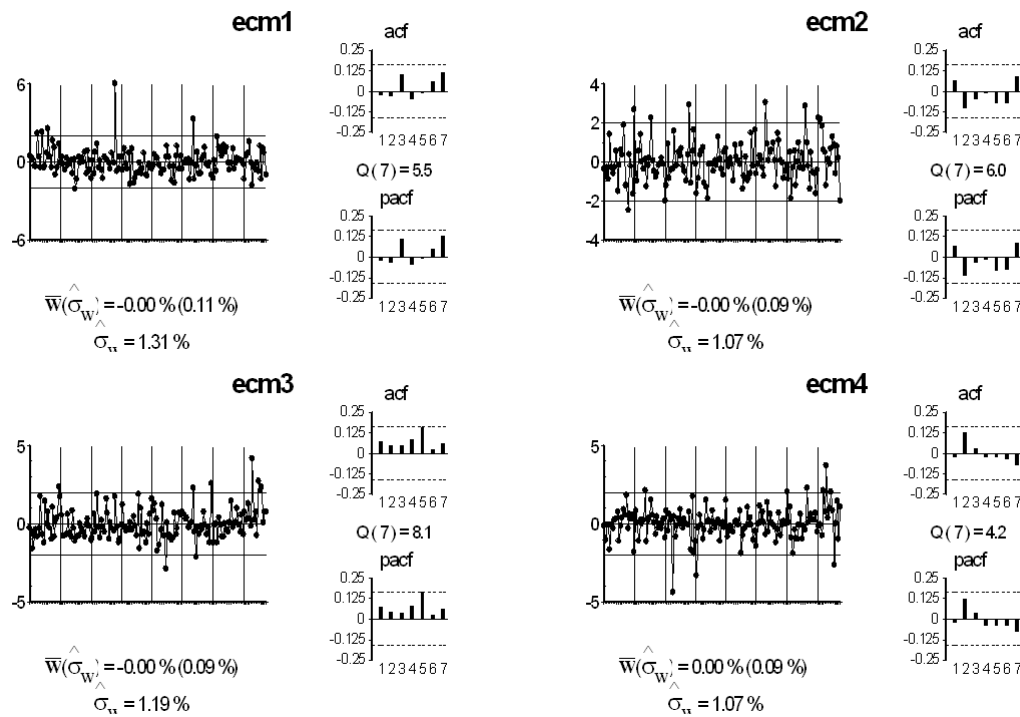


Gráfico 4.7: Acerinox: Relaciones de cointegración

4.A.4.2 Estimación modelo VEC

Se estiman todos los parámetros de forma conjunta por mínimos cuadrados generalizados, salvo los de las relaciones de cointegración que se restringen. Los

resultados aparecen en la tabla 4.19.

Tabla 4.19: Acerinox: Estimación del VEC(2)

Variable dependiente	Ecuaciones ^a				
	∇l_t	∇m_t	∇x_t	∇j_t	∇v_t
μ			0,002 (0,001)	0,004 (0,001)	0,005 (0,002)
$ecm1_{t-1}$	1,17 (0,05)	0,97 (0,07)	1,05 (0,08)	0,99 (0,07)	
$ecm2_{t-1}$	0,92 (0,06)	0,96 (0,08)	1,10 (0,09)		
$ecm3_{t-1}$	1,11 (0,06)	1,23 (0,12)	0,34 (0,14)	0,34 (0,17)	0,51 (0,21)
$ecm4_{t-1}$	0,92 (0,07)		0,14 (0,07)		
∇l_{t-1}	-0,15 (0,07)	-0,097 (0,074)			
∇m_{t-1}	0,098 (0,062)	0,14 (0,07)			
∇x_{t-1}		-0,10 (0,06)		-0,11 (0,07)	-0,19 (0,09)
∇j_{t-1}			-0,14 (0,06)		
∇v_{t-2}	0,10 (0,05)	0,14 (0,06)	0,15 (0,06)	0,14 (0,07)	0,15 (0,09)

^aLa tabla muestra los coeficientes estimados del modelo VEC donde cada columna representa una ecuación del mismo. Entre paréntesis se presentan las desviaciones típicas.

La matriz de covarianzas se presenta en (4.8).

$$\Sigma_u = \begin{pmatrix} 8,59E-05 & 9,23E-05 & 1,01E-04 & 1,04E-04 & 1,05E-04 \\ 9,23E-05 & 2,01E-04 & 2,16E-04 & 2,16E-04 & 2,21E-04 \\ 1,01E-04 & 2,16E-04 & 3,65E-04 & 3,85E-04 & 3,98E-04 \\ 1,04E-04 & 2,16E-04 & 3,85E-04 & 5,20E-04 & 5,55E-04 \\ 1,05E-04 & 2,21E-04 & 3,98E-04 & 5,55E-04 & 7,64E-04 \end{pmatrix} \quad (4.8)$$

En el gráfico 4.8 se presentan los residuos del VEC(2), mientras que la función de correlación cruzada aparece en la tabla 4.20. Ninguna correlación cruzada es significativa, por lo que se considera que el modelo 4.19 representa de forma adecuada la correlación dinámica entre las variables.

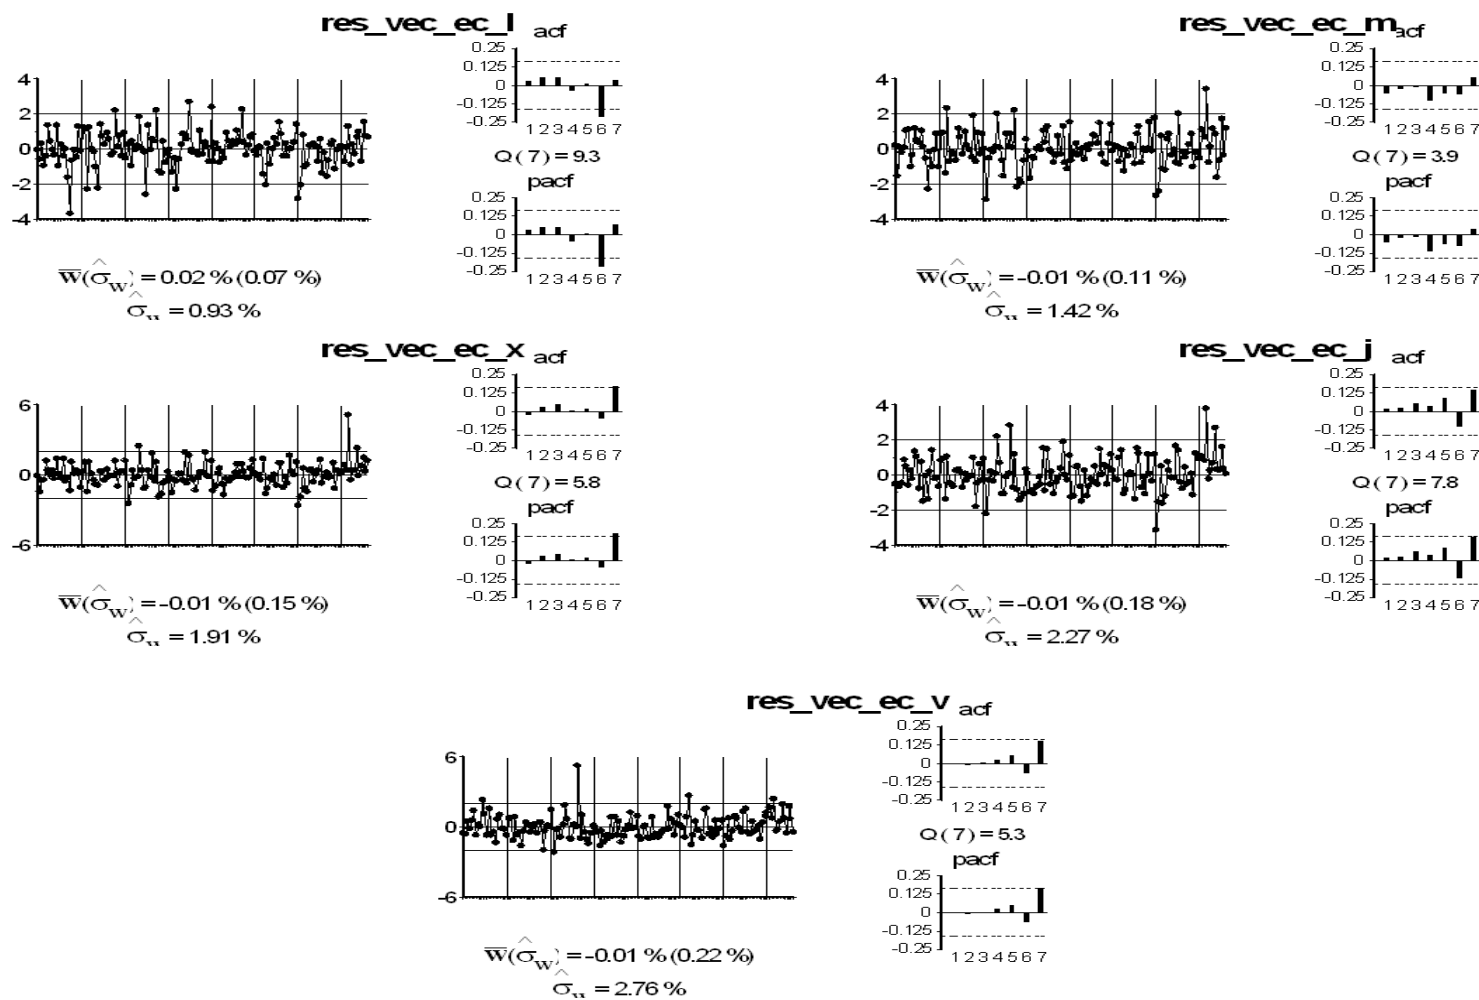


Gráfico 4.8: Acerinox: Residuos del VEC(2)

Tabla 4.20: Acerinox: Función de correlación cruzada residual del VEC(2)

Retardos	r_{11}	r_{12}	r_{13}	r_{14}	r_{15}
1	0,032	-0,004	-0,012	0,003	-0,014
2	0,057	0,022	0,059	0,036	0,001
3	0,057	-0,023	-0,004	0,021	-0,054
4	-0,040	-0,092	-0,093	-0,096	-0,121
5	0,010	-0,034	-0,016	0,000	-0,044
	r_{21}	r_{22}	r_{23}	r_{24}	r_{25}
1	-0,030	-0,052	-0,048	-0,017	-0,037
2	-0,003	-0,023	0,027	0,013	0,010
3	0,035	-0,011	0,027	0,039	-0,035
4	-0,066	-0,108	-0,102	-0,034	-0,035
5	0,005	-0,054	-0,063	0,010	-0,010
	r_{31}	r_{32}	r_{33}	r_{34}	r_{35}
1	-0,021	-0,023	-0,026	0,007	-0,022
2	-0,039	-0,025	0,033	0,019	-0,005
3	0,012	0,001	0,046	0,044	-0,021
4	-0,014	-0,004	0,004	0,047	0,047
5	0,048	-0,022	0,022	0,098	0,063
	r_{41}	r_{42}	r_{43}	r_{44}	r_{45}
1	-0,011	-0,005	-0,011	0,021	-0,014
2	-0,027	-0,036	0,030	0,022	-0,016
3	0,039	0,014	0,076	0,058	0,000
4	-0,040	0,002	0,005	0,040	0,031
5	0,029	0,006	0,042	0,089	0,078
	r_{51}	r_{52}	r_{53}	r_{54}	r_{55}
1	-0,003	-0,018	-0,020	0,035	-0,003
2	-0,011	-0,048	0,003	0,008	-0,014
3	-0,045	-0,018	0,039	0,018	0,001
4	-0,002	0,006	0,015	0,050	0,027
5	0,019	0,043	0,057	0,061	0,051

DT = $\frac{2}{\sqrt{T}} = 0,162$. En * significativos al 95 %.

Para poder representar de forma correcta un modelo periódico, es necesario hacerlo a través de un VEC ortogonalizado. Para obtener la matriz A_0 con la que se ortogonaliza el modelo, se utiliza la matriz 4.8.

$$A_0 = \begin{pmatrix} 1 & 0 & 0 & 0 & 0 \\ -1,08 & 1 & 0 & 0 & 0 \\ -0,04 & -1,16 & 1 & 0 & 0 \\ -0,06 & 0,19 & -1,15 & 1 & 0 \\ 0,06 & -0,01 & 0,18 & -1,21 & 1 \end{pmatrix} \quad (4.9)$$

Premultiplicando el modelo de la tabla 4.19 por la matriz 4.9 se obtiene el modelo ortogonalizado que representa el modelo periódico, el cual se muestra en la tabla 4.21.

Tabla 4.21: Acerinox: Modelo VEC(2) ortogonalizado

Variable dependiente	Ecuaciones				
	∇l_t	∇m_t	∇x_t	∇j_t	∇v_t
μ			0,0010	0,0029	0,0003
$ecm1_{t-1}$	1,17	-0,29	-0,028	-0,11	-0,95
$ecm2_{t-1}$	0,92	-0,023	0,039	-1,14	0,24
$ecm3_{t-1}$	1,11	0,037	-1,01	0,11	0,21
$ecm4_{t-1}$	0,92	-0,99	0,10	-0,22	0,079
∇l_t		1,08	0,043	0,058	-0,058
∇m_t			1,06	-0,19	0,015
∇x_t				1,15	-0,18
∇j_t					1,21
∇l_{t-1}	-0,15	0,060	0,11	-0,0096	-0,0070
∇m_{t-1}	0,098	0,032	-0,15	0,020	0,0037
∇x_{t-1}		-0,10	0,11	-0,13	-0,056
∇j_{t-1}			-0,14	0,17	-0,026
∇v_{t-2}	0,10	0,035	-0,0030	-0,012	0,0082

4.A.5 Altadis

4.A.5.1 Relaciones de cointegración

En la tabla 4.22 se muestra la existencia de las cuatro relaciones de cointegración.

Tabla 4.22: Altadis: Test de cointegración, método de Engle-Granger

Variable dependiente	$p = 0$
$ecm1_t$	-12,66
$ecm2_t$	-11,37
$ecm3_t$	-11,50
$ecm4_t$	-12,33

Valor crítico(95 %):-5,28

(Phillips y Ouliaris (1990)).

Los gráficos de los residuos de estas relaciones de cointegración se presentan en el gráfico 4.9, y en ellos se observa el carácter estacionario de éstas.

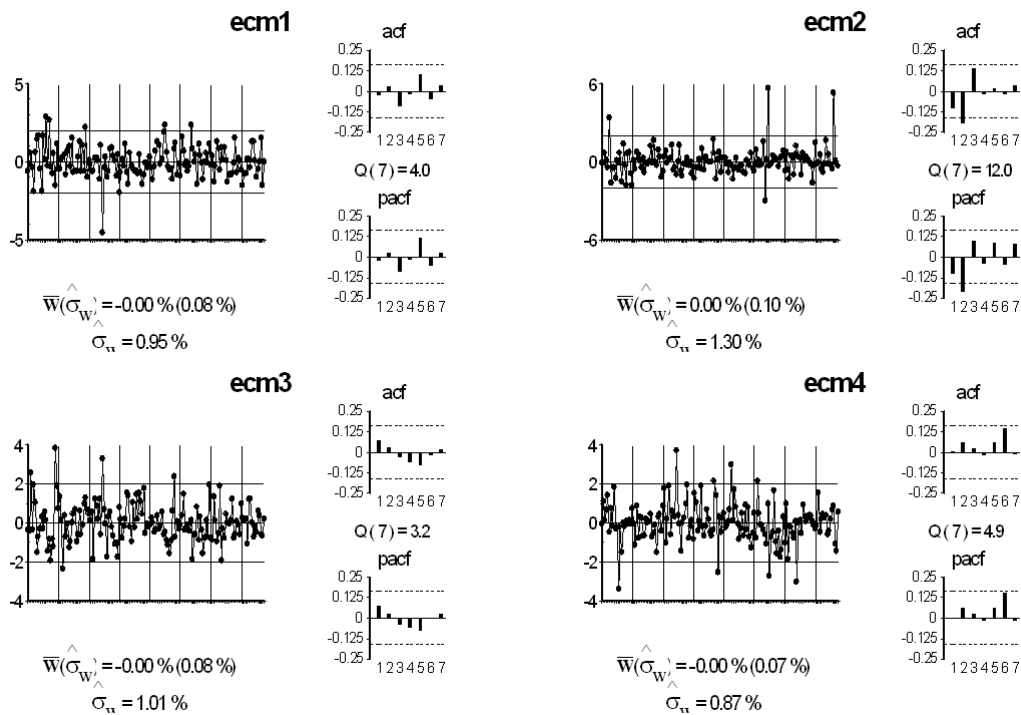


Gráfico 4.9: Altadis: Relaciones de cointegración

4.A.5.2 Estimación modelo VEC

Se estiman, por mínimos cuadrados generalizados, todos los parámetros de forma conjunta, salvo las relaciones de cointegración que se restringen. Los resulta-

dos aparecen en la tabla 4.23.

Tabla 4.23: Altadis: Estimación del VEC(2)

Variable dependiente	Ecuaciones ^a				
	∇l_t	∇m_t	∇x_t	∇j_t	∇v_t
μ	0,002 (0,001)		0,002 (0,001)	0,004 (0,001)	0,005 (0,001)
$ecm1_{t-1}$	1,03 (0,08)	0,99 (0,12)	0,64 (0,18)	0,74 (0,18)	-0,28 (0,18)
$ecm2_{t-1}$	0,99 (0,07)	0,82 (0,07)	0,77 (0,11)		-0,29 (0,09)
$ecm3_{t-1}$	1,08 (0,08)	1,06 (0,08)		0,29 (0,14)	0,44 (0,17)
$ecm4_{t-1}$	1,29 (0,10)	0,24 (0,11)	0,31 (0,16)	0,46 (0,13)	
∇l_{t-1}			-0,12 (0,08)	0,17 (0,07)	
∇m_{t-1}		-0,055 (0,045)			0,26 (0,10)
∇x_{t-1}					-0,30 (0,10)
∇j_{t-1}	-0,068 (0,045)		-0,15 (0,10)	-0,26 (0,07)	
∇v_{t-1}			0,19 (0,11)		
∇l_{t-2}	0,064 (0,028)	0,051 (0,028)			
∇x_{t-2}				0,11 (0,04)	
∇j_{t-2}	-0,17 (0,06)	-0,16 (0,07)	-0,25 (0,10)	-0,39 (0,09)	-0,30 (0,08)
∇v_{t-2}	0,14 (0,06)	0,15 (0,08)	0,29 (0,10)		

^aLa tabla muestra los coeficientes estimados del modelo VEC donde cada columna representa una ecuación del mismo. Entre paréntesis se presentan las desviaciones típicas.

La matriz de covarianzas se presenta en (4.10).

$$\Sigma_u = \begin{pmatrix} 1,00E-04 & 1,13E-04 & 1,18E-04 & 1,18E-04 & 9,72E-05 \\ 1,13E-04 & 2,03E-04 & 2,26E-04 & 2,23E-04 & 1,91E-04 \\ 1,18E-04 & 2,26E-04 & 3,49E-04 & 3,51E-04 & 2,90E-04 \\ 1,18E-04 & 2,23E-04 & 3,51E-04 & 5,10E-04 & 4,61E-04 \\ 9,72E-05 & 1,91E-04 & 2,90E-04 & 4,61E-04 & 5,04E-04 \end{pmatrix} \quad (4.10)$$

Los gráficos de los residuos del VEC(2) aparecen en el gráfico 4.10. Por otro lado, en la tabla 4.24 se presentan las funciones de correlación cruzadas. Dos de las correlaciones son significativas al 95 %, en el retardo 4, sin embargo se considera que el modelo de la tabla 4.23 representa adecuadamente la relación entre las variables.

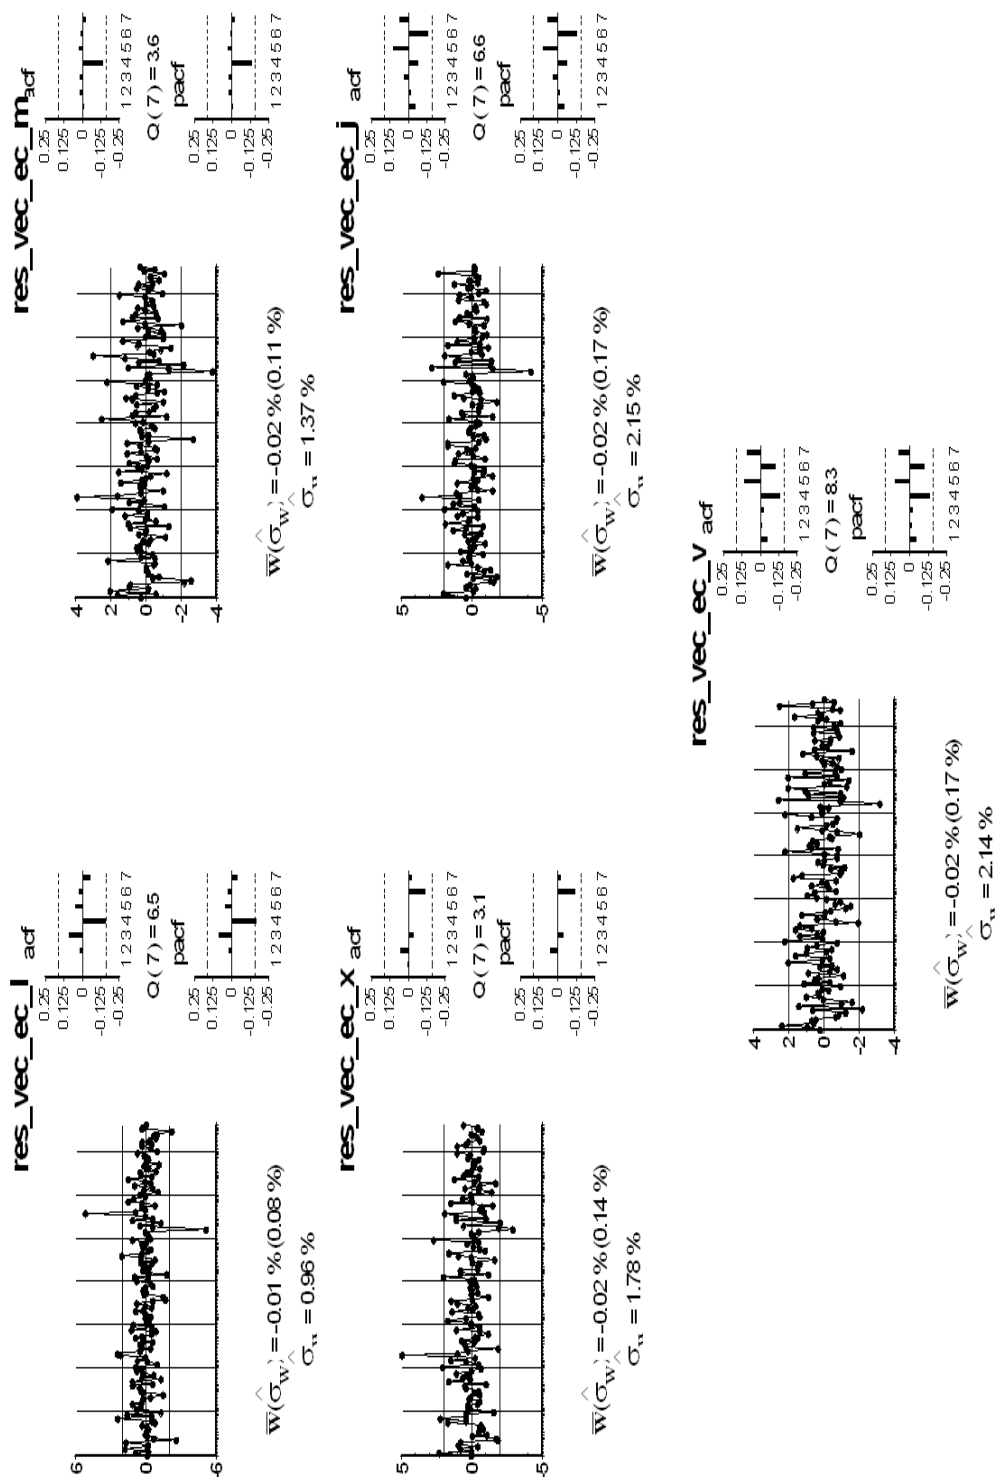


Gráfico 4.10: Altadis: Residuos del VEC(2)

Tabla 4.24: Altadis: Función de correlación cruzada residual del VEC(2)

Retardos	r_{11}	r_{12}	r_{13}	r_{14}	r_{15}
1	-0,006	0,005	0,020	0,011	0,010
2	0,021	0,004	0,000	-0,038	-0,044
3	0,089	0,059	0,048	0,071	0,064
4	-0,162*	-0,183*	-0,069	-0,063	-0,104
5	0,047	-0,009	-0,082	0,015	0,004
	r_{21}	r_{22}	r_{23}	r_{24}	r_{25}
1	-0,025	-0,013	0,006	-0,021	-0,016
2	0,013	0,022	0,043	-0,026	-0,025
3	0,008	0,019	-0,014	0,060	0,042
4	-0,120	-0,143	-0,017	-0,007	-0,073
5	0,060	0,027	-0,025	0,068	0,049
	r_{31}	r_{32}	r_{33}	r_{34}	r_{35}
1	-0,041	-0,019	0,004	-0,025	-0,017
2	0,022	0,040	0,055	-0,012	-0,013
3	0,008	-0,006	-0,038	0,069	0,054
4	-0,102	-0,098	-0,003	0,003	-0,061
5	0,125	0,086	-0,004	0,069	0,046
	r_{41}	r_{42}	r_{43}	r_{44}	r_{45}
1	-0,038	-0,014	-0,006	-0,044	-0,042
2	0,007	0,051	0,082	-0,015	-0,027
3	-0,027	-0,041	-0,043	0,035	0,002
4	-0,127	-0,135	-0,061	-0,072	-0,102
5	0,145	0,078	0,000	0,103	0,095
	r_{51}	r_{52}	r_{53}	r_{54}	r_{55}
1	-0,047	-0,017	-0,016	-0,050	-0,048
2	0,010	0,062	0,095	-0,003	-0,013
3	-0,063	-0,069	-0,069	0,017	-0,024
4	-0,149	-0,129	-0,088	-0,100	-0,133
5	0,142	0,080	-0,003	0,105	0,113

DT = $\frac{2}{\sqrt{T}} = 0,162$. En * significativos al 95 %

Para poder representar de forma correcta un modelo periódico, es necesario hacerlo a través de un VEC ortogonalizado. Para obtener la matriz A_0 con la que se ortogonaliza el modelo, se utiliza la matriz 4.10.

$$A_0 = \begin{pmatrix} 1 & 0 & 0 & 0 & 0 \\ -1,13 & 1 & 0 & 0 & 0 \\ 0,23 & -1,22 & 1 & 0 & 0 \\ -0,08 & 0,11 & -1,04 & 1 & 0 \\ 0,16 & -0,23 & 0,35 & -1,07 & 1 \end{pmatrix} \quad (4.11)$$

Premultiplicando el modelo de la tabla 4.23 por la matriz 4.11 se obtiene el modelo ortogonalizado que representa el modelo periódico, el cual se muestra en la tabla 4.25.

Tabla 4.25: Altadis: Modelo VEC(2) ortogonalizado

Variable dependiente	Ecuaciones				
	∇l_t	∇m_t	∇x_t	∇j_t	∇v_t
μ	0,0020	-0,0023	0,0025	0,0018	0,0017
$ecm1_{t-1}$	1,03	-0,16	-0,33	0,10	-0,92
$ecm2_{t-1}$	0,99	-0,30	0,0032	-0,79	-0,051
$ecm3_{t-1}$	1,08	-0,15	-1,05	0,32	0,059
$ecm4_{t-1}$	1,29	-1,21	0,32	0,057	-0,23
∇l_t		1,13	-0,23	0,076	-0,16
∇m_t			1,22	-0,11	0,23
∇x_t				1,04	-0,35
∇j_t					1,07
∇l_{t-1}			-0,12	0,30	-0,22
∇m_{t-1}		-0,055	0,067	-0,0061	0,28
∇x_{t-1}					-0,30
∇j_{t-1}	-0,068	0,077	-0,17	-0,096	0,22
∇v_{t-1}			0,19	-0,19	0,066
∇l_{t-2}	0,064	-0,021	-0,048	0,0008	-0,0017
∇x_{t-2}				0,11	-0,12
∇j_{t-2}	-0,17	0,033	-0,096	-0,14	0,039
∇v_{t-2}	0,14	-0,0097	0,14	-0,29	0,089

4.A.6 Acciona

4.A.6.1 Relaciones de cointegración

Se comprueba la existencia de las cuatro relaciones de cointegración en la tabla 4.26.

Tabla 4.26: Acciona: Test de cointegración, método de Engle-Granger

Variable dependiente	$p = 0$
$ecm1_t$	-11,96
$ecm2_t$	-13,89
$ecm3_t$	-11,46
$ecm4_t$	-11,29

Valor crítico(95 %):-5,28
(Phillips y Ouliaris (1990)).

Los gráficos de los residuos de estas relaciones de cointegración se presentan en el gráfico 4.11 , y en él se observa el carácter estacionario de éstas.

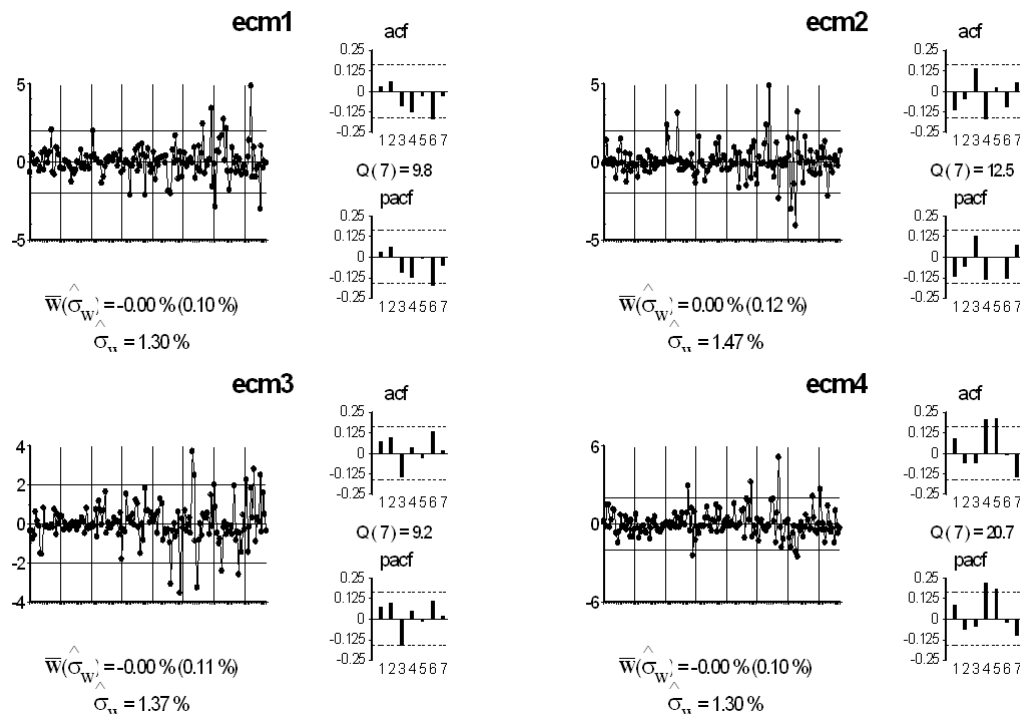


Gráfico 4.11: Acciona: Relaciones de cointegración

4.A.6.2 Estimación modelo VEC

Se estiman todos los parámetros de forma conjunta por mínimos cuadrados generalizados, salvo los de las relaciones de cointegración que se restringen. Los

resultados aparecen en la tabla 4.27.

Tabla 4.27: Acciona: Estimación del VEC(1)

Variable dependiente	Ecuaciones ^a				
	∇l_t	∇m_t	∇x_t	∇j_t	∇v_t
$ecm1_{t-1}$	1,14 (0,07)	1,25 (0,14)	1,57 (0,20)	1,70 (0,25)	0,95 (0,28)
$ecm2_{t-1}$	1,08 (0,06)	1,43 (0,14)	1,71 (0,20)	0,60 (0,25)	0,80 (0,28)
$ecm3_{t-1}$	0,96 (0,06)	1,00 (0,14)	0,33 (0,19)	0,62 (0,24)	0,61 (0,27)
$ecm4_{t-1}$	1,29 (0,09)	0,51 (0,16)	0,57 (0,20)	0,62 (0,26)	0,58 (0,29)
∇l_{t-1}	0,18 (0,06)	0,16 (0,07)	0,14 (0,06)	0,25 (0,08)	0,21 (0,08)
∇m_{t-1}	-0,17 (0,06)	-0,13 (0,06)			
∇x_{t-1}				-0,13 (0,05)	
∇v_{t-1}		-0,12 (0,10)	-0,37 (0,15)	-0,41 (0,19)	-0,65 (0,22)

^aLa tabla muestra los coeficientes estimados del modelo VEC donde cada columna representa una ecuación del mismo. Entre paréntesis se presentan las desviaciones típicas.

La matriz de covarianzas se presenta en (4.12).

$$\Sigma_u = \begin{pmatrix} 1,22E-04 & 1,28E-04 & 1,26E-04 & 1,28E-04 & 1,15E-04 \\ 1,28E-04 & 2,92E-04 & 2,96E-04 & 2,91E-04 & 2,76E-04 \\ 1,26E-04 & 2,96E-04 & 4,82E-04 & 4,96E-04 & 4,80E-04 \\ 1,28E-04 & 2,91E-04 & 4,96E-04 & 7,16E-04 & 7,17E-04 \\ 1,15E-04 & 2,76E-04 & 4,80E-04 & 7,17E-04 & 8,77E-04 \end{pmatrix} \quad (4.12)$$

El gráfico 4.12 muestra los residuos del VEC(1). Por otro lado, en la tabla 4.28 se presentan las funciones de correlación cruzadas. Sólo una de ellas es significativa, por lo cual estos resultados sugieren que el modelo de la tabla 4.27 representa de forma adecuada la correlación dinámica entre las variables.

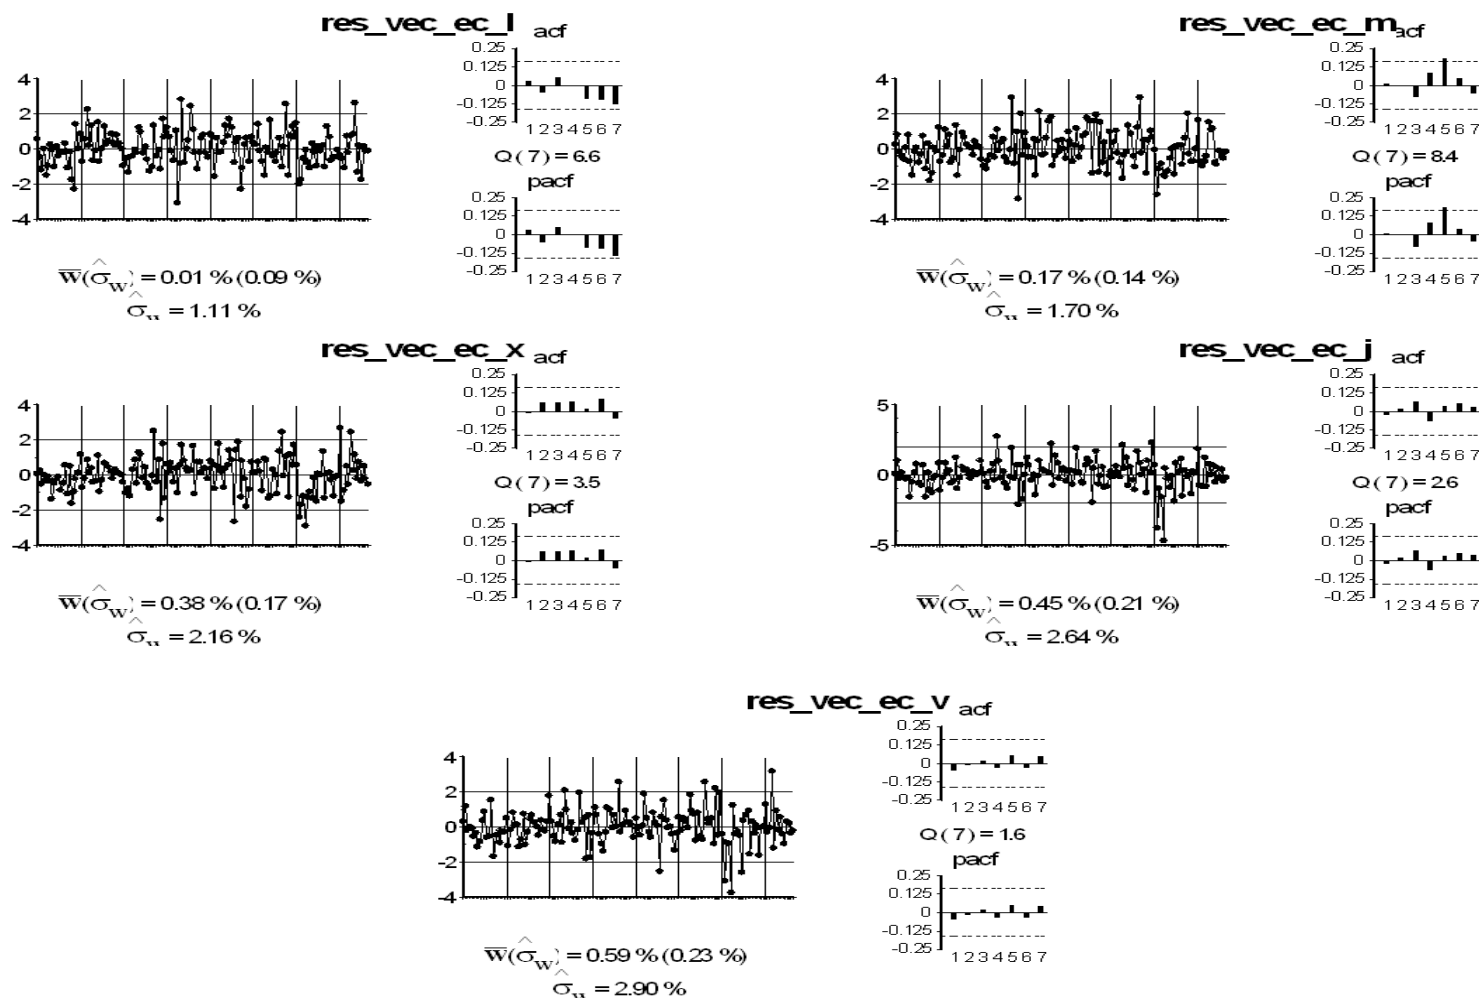


Gráfico 4.12: Acciona: Residuos del VEC(1)

Tabla 4.28: Acciona: Función de correlación cruzada residual del VEC(1)

Retardos	r_{11}	r_{12}	r_{13}	r_{14}	r_{15}
1	0,031	0,037	-0,004	-0,023	-0,025
2	-0,050	-0,020	0,052	-0,032	-0,019
3	0,051	-0,025	0,085	0,079	0,114
4	0,000	-0,027	-0,005	-0,057	-0,022
5	-0,091	0,042	0,039	0,043	0,047
	r_{21}	r_{22}	r_{23}	r_{24}	r_{25}
1	0,023	0,009	-0,021	-0,031	-0,030
2	-0,025	-0,004	0,032	-0,008	-0,007
3	0,024	-0,082	0,062	0,069	0,072
4	0,013	0,080	0,015	0,022	0,032
5	0,034	0,183*	0,096	0,147	0,134
	r_{31}	r_{32}	r_{33}	r_{34}	r_{35}
1	-0,002	0,001	-0,010	-0,023	-0,016
2	0,069	0,042	0,060	0,013	0,022
3	0,058	0,021	0,059	0,027	0,002
4	0,049	0,121	0,068	0,039	0,055
5	0,037	0,091	0,022	0,068	0,058
	r_{41}	r_{42}	r_{43}	r_{44}	r_{45}
1	-0,005	0,000	-0,017	-0,028	-0,027
2	0,060	0,009	0,054	0,020	0,027
3	0,073	0,071	0,066	0,067	0,056
4	0,014	0,056	-0,010	-0,069	-0,056
5	0,054	0,040	-0,006	0,040	0,022
	r_{51}	r_{52}	r_{53}	r_{54}	r_{55}
1	-0,015	-0,016	-0,032	-0,047	-0,044
2	-0,035	-0,039	0,006	-0,025	-0,013
3	0,010	0,053	0,063	0,039	0,020
4	0,052	0,105	0,027	-0,021	-0,036
5	0,039	0,049	0,028	0,090	0,056

DT= $\frac{2}{\sqrt{T}}$ = 0,161. En * significativos al 95 %.

Es necesario obtener un VEC ortogonalizado para poder representar de forma correcta un modelo periódico. Para obtener la matriz A_0 con la que se ortogonaliza el modelo, se utiliza la matriz 4.12.

$$A_0 = \begin{pmatrix} 1 & 0 & 0 & 0 & 0 \\ -1,05 & 1 & 0 & 0 & 0 \\ 0,05 & -1,03 & 1 & 0 & 0 \\ -0,05 & 0,14 & -1,04 & 1 & 0 \\ 0,09 & -0,005 & 0,11 & -1,09 & 1 \end{pmatrix} \quad (4.13)$$

Premultiplicando el modelo de la tabla 4.27 por la matriz 4.13 se obtiene el modelo ortogonalizado que representa el modelo periódico, el cual aparece en la tabla 4.29.

Tabla 4.29: Acciona: Modelo VEC(1) ortogonalizado

Variable dependiente	Ecuaciones				
	∇l_t	∇m_t	∇x_t	∇j_t	∇v_t
$ecm1_{t-1}$	1,14	0,060	0,35	0,080	-0,64
$ecm2_{t-1}$	1,08	0,31	0,28	-1,13	0,41
$ecm3_{t-1}$	0,96	-0,0030	-0,65	0,35	0,054
$ecm4_{t-1}$	1,29	-0,85	0,11	0,0027	0,073
∇l_t		1,05	-0,051	0,048	-0,087
∇m_t			1,03	-0,14	0,045
∇x_t				1,10	-0,11
∇j_t					1,09
∇l_{t-1}	0,18	-0,028	-0,019	0,11	-0,036
∇m_{t-1}	-0,17	0,053	0,12	-0,0096	-0,015
∇x_{t-1}				-0,13	0,14
∇v_{t-1}		-0,12	-0,25	-0,018	-0,24
∇l_{t-2}	0,064	-0,021	-0,048	0,0008	-0,0017

4.A.7 BBVA

4.A.7.1 Relaciones de cointegración

Se comprueba la existencia de las relaciones de 4.1 en la tabla 4.30.

Tabla 4.30: BBVA: Test de cointegración, método de Engle-Granger

Variable dependiente	$p = 0$
$ecm1_t$	-11,52
$ecm2_t$	-12,20
$ecm3_t$	-11,57
$ecm4_t$	-10,88

Valor crítico(95 %):-5,28

(Phillips y Ouliaris (1990)).

Los gráficos de los residuos de estas relaciones de cointegración se presentan en el gráfico 4.13 , y en él se observa el carácter estacionario de éstas.

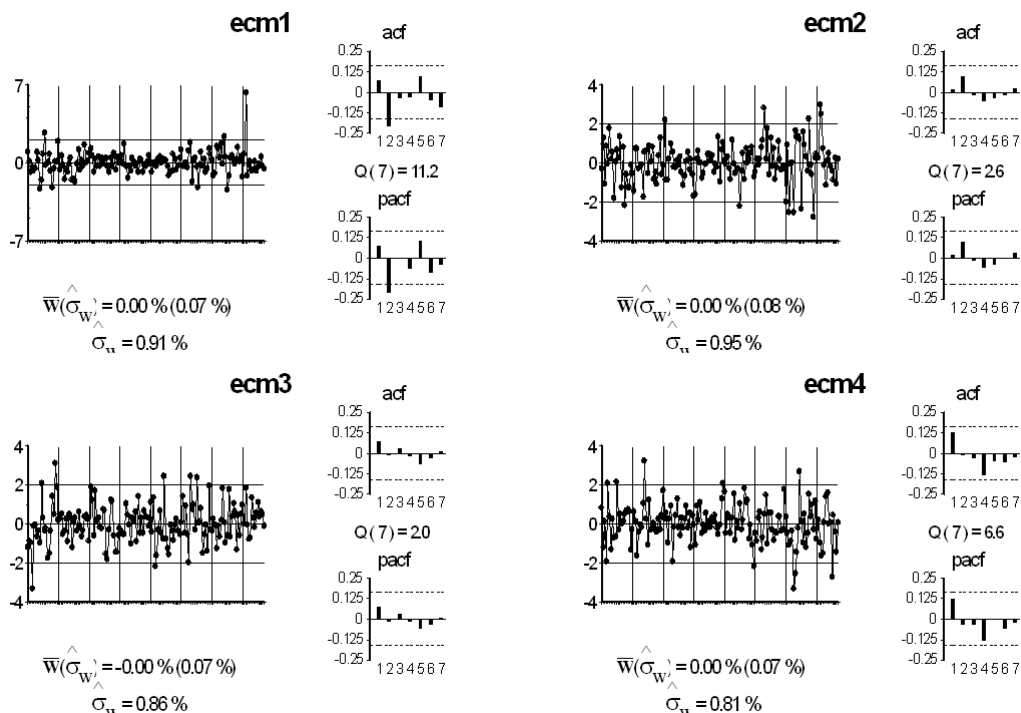


Gráfico 4.13: BBVA: Relaciones de cointegración

4.A.7.2 Estimación modelo VEC

Se estiman todos los parámetros de forma conjunta por mínimos cuadrados generalizados, menos los de las relaciones de cointegración, que se restringen. Los resultados aparecen en la tabla 4.31.

Tabla 4.31: BBVA: Estimación del VEC(1)

Variable dependiente	Ecuaciones ^a				
	∇l_t	∇m_t	∇x_t	∇j_t	∇v_t
μ	-0,002 (0,001)	-0,001 (0,001)		0,002 (0,001)	0,004 (0,001)
$ecm1_{t-1}$	0,98 (0,10)	0,89 (0,12)	0,97 (0,11)	1,07 (0,09)	
$ecm2_{t-1}$	1,01 (0,09)	0,92 (0,11)	0,85 (0,09)		
$ecm3_{t-1}$	0,87 (0,08)	0,83 (0,08)			0,23 (0,10)
$ecm4_{t-1}$	1,01 (0,07)				
∇l_{t-1}		-0,071 (0,028)	-0,11 (0,04)	-0,14 (0,06)	-0,19 (0,10)
∇m_{t-1}					0,25 (0,09)
∇x_{t-1}				0,16 (0,06)	
∇j_{t-1}				-0,19 (0,07)	-0,47 (0,11)
∇v_{t-1}		0,072 (0,035)			0,18 (0,08)

^aLa tabla muestra los coeficientes estimados del modelo VEC donde cada columna representa una ecuación del mismo. Entre paréntesis se presentan las desviaciones típicas.

La matriz de covarianzas se presenta en (4.14).

$$\Sigma_u = \begin{pmatrix} 1,39E-04 & 1,53E-04 & 1,40E-04 & 1,35E-04 & 1,32E-04 \\ 1,53E-04 & 2,30E-04 & 2,24E-04 & 2,20E-04 & 2,13E-04 \\ 1,40E-04 & 2,24E-04 & 2,88E-04 & 2,98E-04 & 2,95E-04 \\ 1,35E-04 & 2,20E-04 & 2,98E-04 & 3,96E-04 & 4,15E-04 \\ 1,32E-04 & 2,13E-04 & 2,95E-04 & 4,15E-04 & 5,05E-04 \end{pmatrix} \quad (4.14)$$

En la tabla 4.32 se presentan las funciones de correlación cruzadas. En ellas no aparece ninguna correlación significativa, por lo que se considera que el modelo de la tabla 4.31 representa de forma adecuada la relación entre las variables. Los residuos del VEC(1) aparecen en el gráfico 4.14.

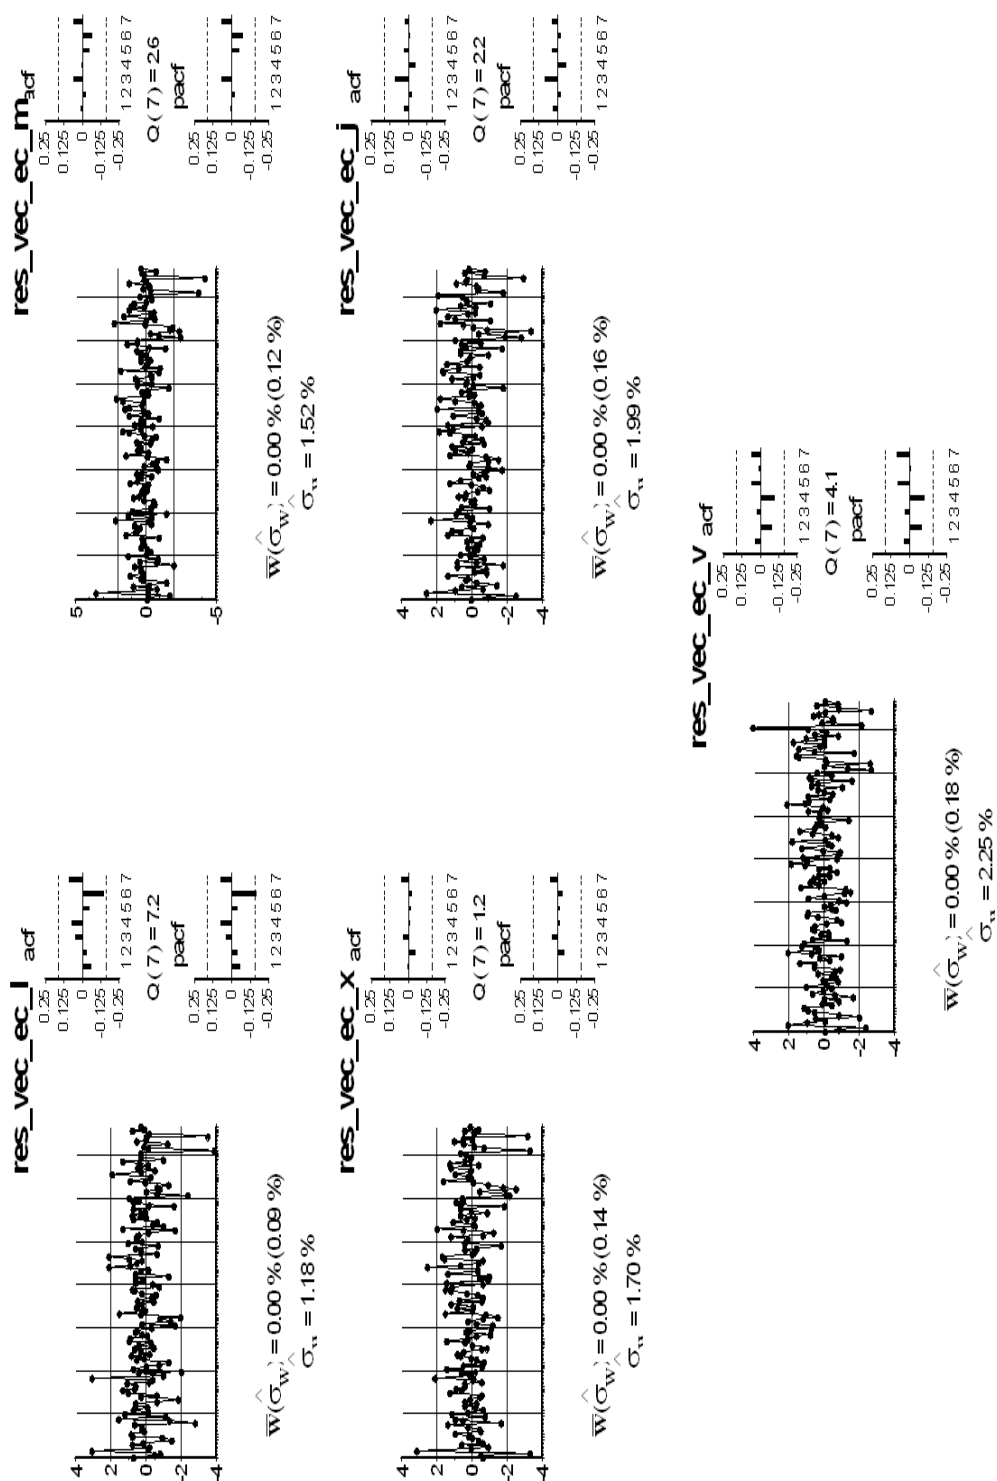


Gráfico 4.14: BBVA: Residuos del VEC(1)

Tabla 4.32: BBVA: Función de correlación cruzada residual del VEC(1)

Retardos	r_{11}	r_{12}	r_{13}	r_{14}	r_{15}
1	-0,065	-0,013	-0,029	-0,011	-0,009
2	-0,036	-0,082	-0,090	-0,072	-0,110
3	0,046	0,057	0,052	0,045	0,009
4	0,073	0,071	0,062	0,024	-0,026
5	-0,046	-0,041	0,018	0,097	0,104
	r_{21}	r_{22}	r_{23}	r_{24}	r_{25}
1	-0,055	0,011	-0,006	0,011	0,017
2	-0,002	-0,026	-0,037	-0,022	-0,073
3	0,072	0,065	0,058	0,080	0,060
4	0,046	0,005	0,006	0,013	-0,015
5	-0,034	-0,049	-0,016	0,059	0,077
	r_{31}	r_{32}	r_{33}	r_{34}	r_{35}
1	-0,045	0,030	0,004	0,022	0,022
2	-0,046	-0,044	-0,049	-0,031	-0,077
3	0,044	0,037	0,038	0,062	0,039
4	0,026	-0,016	-0,013	0,017	0,003
5	-0,026	-0,034	-0,018	0,052	0,091
	r_{41}	r_{42}	r_{43}	r_{44}	r_{45}
1	-0,035	0,027	0,011	0,036	0,041
2	-0,070	-0,069	-0,043	-0,027	-0,077
3	0,137	0,098	0,079	0,088	0,076
4	-0,026	-0,071	-0,073	-0,050	-0,069
5	-0,054	-0,059	-0,016	0,033	0,059
	r_{51}	r_{52}	r_{53}	r_{54}	r_{55}
1	-0,018	0,007	-0,010	0,027	0,037
2	-0,063	-0,089	-0,054	-0,036	-0,080
3	0,125	0,075	0,036	0,030	0,025
4	0,022	-0,037	-0,056	-0,070	-0,095
5	-0,068	-0,056	-0,010	0,027	0,063

DT = $\frac{2}{\sqrt{T}} = 0,161$. En * significativos al 95 %.

Para representar de forma correcta un modelo periódico, es necesario obtener un VEC ortogonalizado. Para conseguir la matriz A_0 con la que se ortogonaliza el modelo, se utiliza la matriz 4.14.

$$A_0 = \begin{pmatrix} 1 & 0 & 0 & 0 & 0 \\ -1,10 & 1 & 0 & 0 & 0 \\ 0,25 & -1,14 & 1 & 0 & 0 \\ 0,02 & 0,18 & -1,18 & 1 & 0 \\ -0,06 & 0,09 & 0,21 & -1,23 & 1 \end{pmatrix} \quad (4.15)$$

Premultiplicando el modelo de la tabla 4.31 por la matriz 4.15 se obtiene el modelo ortogonalizado que representa el modelo periódico, el cual se muestra en la tabla 4.33.

Tabla 4.33: BBVA: Modelo VEC(1) ortogonalizado

Variable dependiente	Ecuaciones				
	∇l_t	∇m_t	∇x_t	∇j_t	∇v_t
μ	-0,0020	0,0012	0,0006	0,0018	0,0016
$ecm1_{t-1}$	0,98	-0,19	0,19	0,10	-1,09
$ecm2_{t-1}$	1,01	-0,20	0,055	-0,82	0,20
$ecm3_{t-1}$	0,88	-0,14	-0,73	0,16	0,25
$ecm4_{t-1}$	1,01	-1,11	0,25	0,017	-0,065
∇l_t		1,10	-0,25	-0,017	0,064
∇m_t			1,14	-0,18	-0,092
∇x_t				1,18	-0,21
∇j_t					1,23
∇l_{t-1}		-0,071	-0,026	-0,028	-0,051
∇m_{t-1}					0,26
∇x_{t-1}				0,16	-0,20
∇j_{t-1}				-0,19	-0,23
∇v_{t-1}		0,072	-0,082	0,013	0,18

4.A.8 Bankinter

4.A.8.1 Relaciones de cointegración

En la tabla 4.34 se muestra la existencia de las relaciones de cointegración.

Tabla 4.34: Bankinter: Test de cointegración, método de Engle-Granger

Variable dependiente	$p = 0$
$ecm1_t$	-13,20
$ecm2_t$	-5,87
$ecm3_t$	-11,22
$ecm4_t$	-11,10

Valor crítico(95 %):-5,28
(Phillips y Ouliaris (1990)).

Los residuos de estas relaciones de cointegración se presentan en el gráfico 4.15 , y en él se observa el carácter estacionario de éstas.

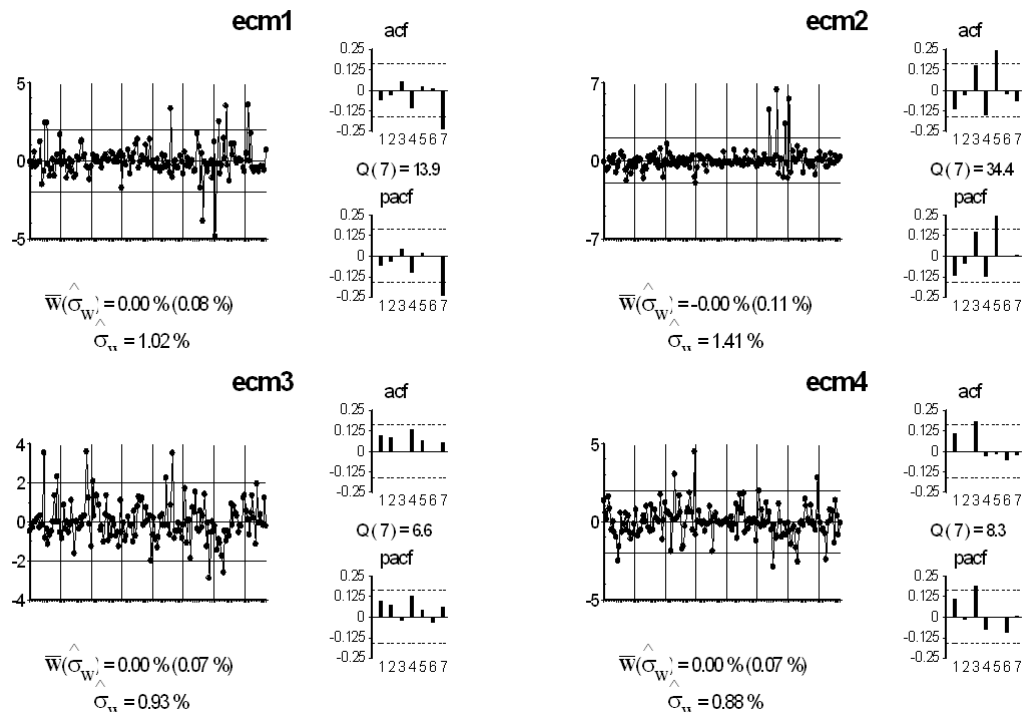


Gráfico 4.15: Bankinter: Relaciones de cointegración

4.A.8.2 Estimación modelo VEC

Se estiman todos los parámetros de forma conjunta por mínimos cuadrados generalizados, salvo los de las relaciones de cointegración, que se restringen. Los resultados aparecen en la tabla 4.35.

Tabla 4.35: Bankinter: Estimación del VEC(0)

Variable dependiente	Ecuaciones ^a				
	∇l_t	∇m_t	∇x_t	∇j_t	∇v_t
$ecm1_{t-1}$	1,35 (0,08)	1,34 (0,14)	1,30 (0,10)	1,56 (0,18)	0,50 (0,18)
$ecm2_{t-1}$	1,05 (0,05)	1,01 (0,05)	1,02 (0,05)		
$ecm3_{t-1}$	0,93 (0,10)	0,85 (0,08)			
$ecm4_{t-1}$	0,96 (0,06)				

^aLa tabla muestra los coeficientes estimados del modelo VEC donde cada columna representa una ecuación del mismo. Entre paréntesis se presentan las desviaciones típicas.

La matriz de covarianzas se presenta en (4.16).

$$\Sigma_u = \begin{pmatrix} 9,95E-05 & 1,04E-04 & 9,95E-05 & 1,16E-04 & 1,08E-04 \\ 1,04E-04 & 2,97E-04 & 1,93E-04 & 3,19E-04 & 3,10E-04 \\ 9,95E-05 & 1,93E-04 & 1,75E-04 & 1,99E-04 & 1,93E-04 \\ 1,16E-04 & 3,19E-04 & 1,99E-04 & 5,32E-04 & 4,93E-04 \\ 1,08E-04 & 3,10E-04 & 1,93E-04 & 4,93E-04 & 5,59E-04 \end{pmatrix} \quad (4.16)$$

El gráfico 4.16 muestra los residuos del VEC(0). Por otro lado, en la tabla 4.36 se presentan las funciones de correlación cruzadas. Cuatro de las correlaciones son significativas, sin embargo, se considera que el modelo de la tabla 4.35 representa de forma adecuada la correlación dinámica entre las variables.

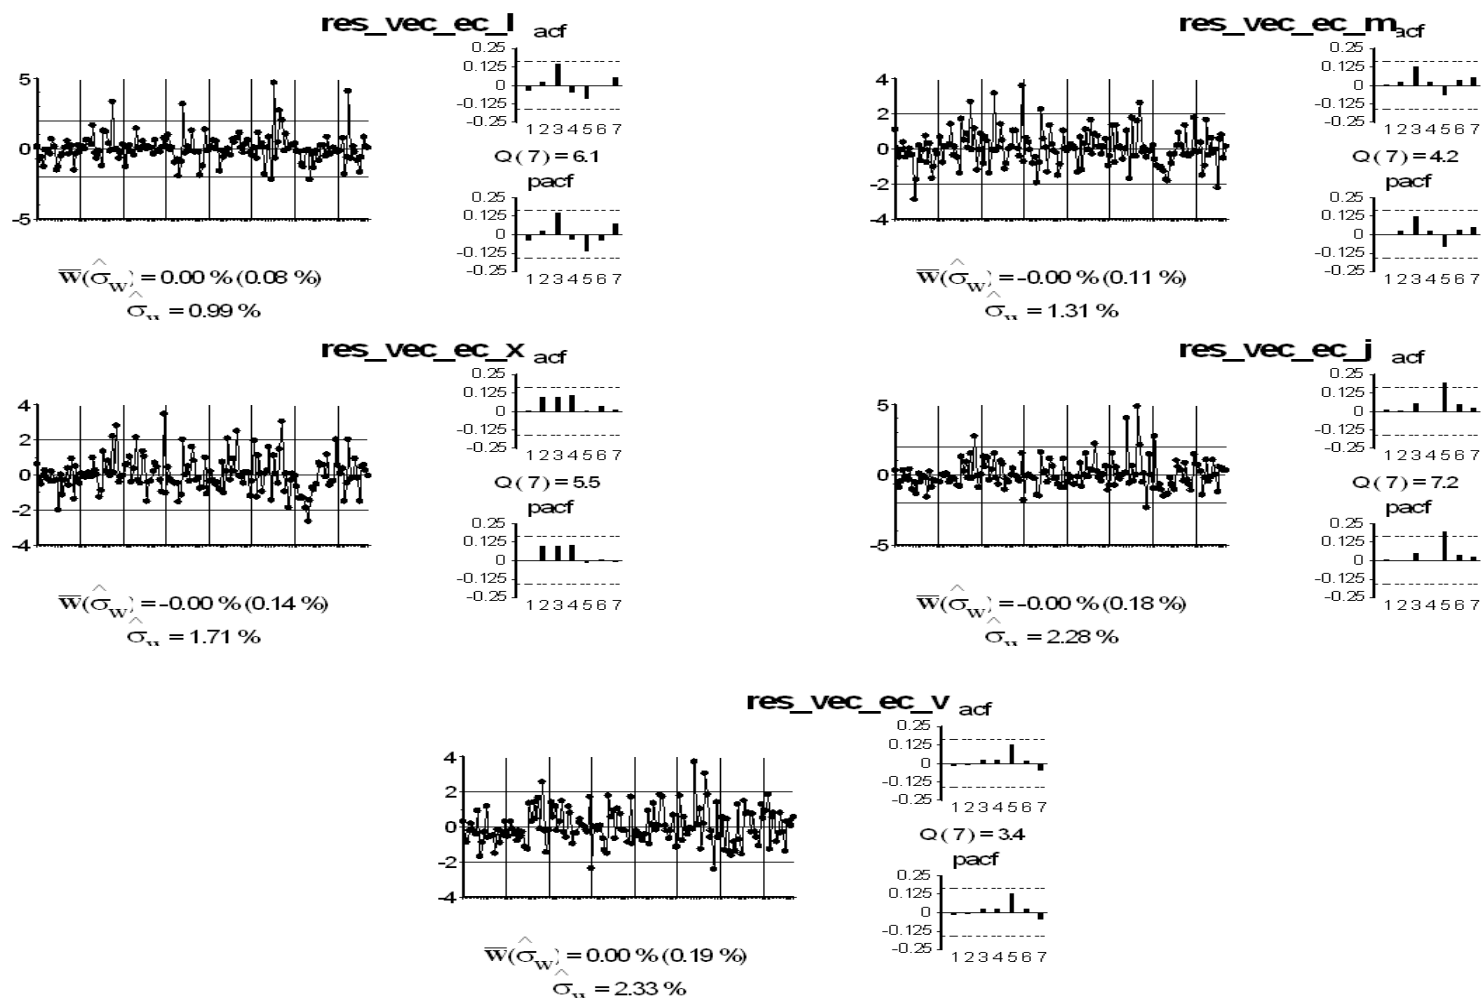


Gráfico 4.16: Bankinter: Residuos del VEC(0)

Tabla 4.36: Bankinter: Función de correlación cruzada residual del VEC(0)

Retardos	r_{11}	r_{12}	r_{13}	r_{14}	r_{15}
1	-0,040	-0,020	-0,017	0,002	0,003
2	0,024	0,056	0,098	0,147	0,160
3	0,148	0,125	0,075	0,049	0,078
4	-0,045	-0,020	0,034	0,068	0,106
5	-0,094	-0,029	0,014	0,087	0,069
	r_{21}	r_{22}	r_{23}	r_{24}	r_{25}
1	-0,001	0,003	-0,001	0,009	0,008
2	0,025	0,023	0,067	0,056	0,053
3	0,033	0,124	0,080	0,027	0,049
4	0,038	0,024	0,069	0,055	0,112
5	-0,139	-0,072	0,014	0,037	0,082
	r_{31}	r_{32}	r_{33}	r_{34}	r_{35}
1	0,021	0,013	0,002	0,010	0,013
2	0,020	0,057	0,100	0,046	0,060
3	0,087	0,155	0,096	0,045	0,066
4	0,030	0,055	0,114	0,044	0,123
5	-0,187*	-0,086	0,004	-0,001	0,049
	r_{41}	r_{42}	r_{43}	r_{44}	r_{45}
1	0,010	0,004	-0,006	0,010	0,011
2	-0,012	0,008	0,075	0,002	-0,035
3	0,179*	0,136	0,047	0,051	0,080
4	-0,042	0,012	0,060	-0,006	0,051
5	-0,026	0,012	0,104	0,198*	0,175*
	r_{51}	r_{52}	r_{53}	r_{54}	r_{55}
1	-0,071	-0,051	-0,046	-0,014	-0,016
2	-0,006	-0,017	0,064	0,032	-0,008
3	0,080	0,106	0,029	-0,017	0,023
4	-0,084	-0,007	0,063	-0,010	0,024
5	-0,080	-0,039	0,038	0,143	0,130

DT = $\frac{2}{\sqrt{T}} = 0,161$. En * significativos al 95 %.

Se necesita ortogonalizar el VEC, para representar de forma correcta el modelo periódico. Para conseguir la matriz A_0 con la que se ortogonaliza el modelo, se utiliza la matriz 4.16.

$$A_0 = \begin{pmatrix} 1 & 0 & 0 & 0 & 0 \\ -1,04 & 1 & 0 & 0 & 0 \\ -0,51 & -0,47 & 1 & 0 & 0 \\ -0,23 & -1,20 & 0,31 & 1 & 0 \\ 0,08 & -0,13 & -0,04 & -0,85 & 1 \end{pmatrix} \quad (4.17)$$

Premultiplicando el modelo de la tabla 4.35 por la matriz 4.17 se obtiene el modelo ortogonalizado que representa el modelo periódico, el cual aparece en la tabla 4.37.

Tabla 4.37: Bankinter: Modelo VEC(0) ortogonalizado

Variable dependiente	Ecuaciones				
	∇l_t	∇m_t	∇x_t	∇j_t	∇v_t
$ecm1_{t-1}$	1,35	-0,062	-0,016	0,040	-0,94
$ecm2_{t-1}$	1,05	-0,079	0,0054	-1,14	-0,085
$ecm3_{t-1}$	0,93	-0,12	-0,87	-1,23	-0,032
$ecm4_{t-1}$	0,97	-1,00	-0,49	-0,23	0,079
∇l_t		1,04	0,51	0,23	-0,082
∇m_t			0,47	1,20	0,13
∇x_t				-0,31	0,041
∇j_t					0,85

4.A.9 Banesto

4.A.9.1 Relaciones de cointegración

En la tabla 4.38 se muestra la existencia de estas relaciones de cointegración.

Tabla 4.38: Banesto: Test de cointegración, método de Engle-Granger

Variable dependiente	$p = 0$
$ecm1_t$	-11,28
$ecm2_t$	-13,14
$ecm3_t$	-9,68
$ecm4_t$	-12,58

Valor crítico(95 %):-5,28

(Phillips y Ouliaris (1990)).

Los gráficos de los residuos de estas relaciones de cointegración se presentan en el gráfico 4.17 , y en él se observa el carácter estacionario de éstas.

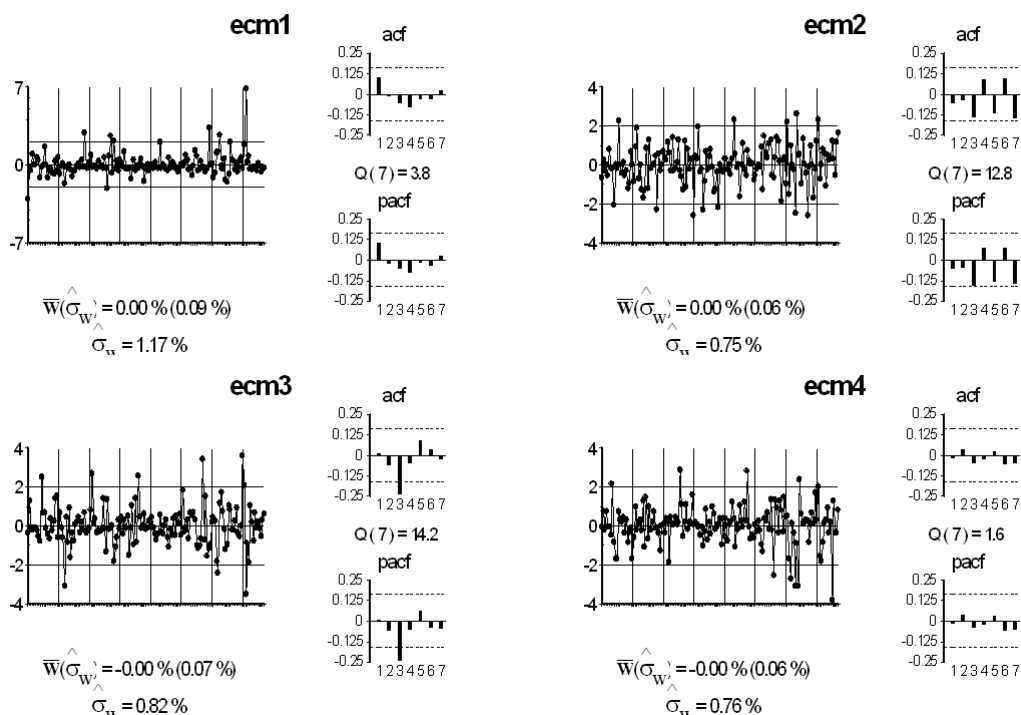


Gráfico 4.17: Banesto: Relaciones de cointegración

4.A.9.2 Estimación modelo VEC

Se estiman todos los parámetros de forma conjunta por mínimos cuadrados generalizados, menos los de las relaciones de cointegración, que se restringen. Los resultados aparecen en la tabla 4.39.

Tabla 4.39: Banesto: Estimación del VEC(2)

Variable dependiente	Ecuaciones ^a				∇v_t
	∇l_t	∇m_t	∇x_t	∇j_t	
μ					0,002 (0,001)
$ecm1_{t-1}$	1,14 (0,09)	0,96 (0,07)	0,96 (0,08)	1,07 (0,09)	
$ecm2_{t-1}$	1,34 (0,11)	1,25 (0,11)	0,95 (0,07)		
$ecm3_{t-1}$	1,18 (0,09)	1,07 (0,08)			
$ecm4_{t-1}$	1,12 (0,10)				
∇l_{t-1}	0,17 (0,06)	0,19 (0,06)			
∇j_{t-1}		-0,10 (0,04)		0,11 (0,05)	
∇v_{t-1}	-0,14 (0,07)			-0,17 (0,06)	
∇l_{t-2}			-0,16 (0,03)	-0,21 (0,04)	
∇m_{t-2}					-0,43 (0,09)
∇x_{t-2}		-0,10 (0,03)			0,27 (0,09)
∇j_{t-2}				0,13 (0,04)	
∇v_{t-2}	-0,18 (0,06)	-0,15 (0,06)	-0,082 (0,044)	-0,18 (0,05)	

^aLa tabla muestra los coeficientes estimados del modelo VEC donde cada columna representa una ecuación del mismo. Entre paréntesis se presentan las desviaciones típicas.

La matriz de covarianzas se presenta en (4.18).

$$\Sigma_u = \begin{pmatrix} 7,46E-05 & 9,43E-05 & 9,13E-05 & 9,42E-05 & 8,30E-05 \\ 9,43E-05 & 1,68E-04 & 1,69E-04 & 1,80E-04 & 1,61E-04 \\ 9,13E-05 & 1,69E-04 & 2,32E-04 & 2,53E-04 & 2,17E-04 \\ 9,42E-05 & 1,80E-04 & 2,53E-04 & 3,26E-04 & 3,08E-04 \\ 8,30E-05 & 1,61E-04 & 2,17E-04 & 3,08E-04 & 4,04E-04 \end{pmatrix} \quad (4.18)$$

Los residuos del VEC(2) aparecen en el gráfico 4.18. Por su parte, en la tabla 4.40 se presentan las funciones de correlación cruzadas. En ninguna de ellas se aprecian correlaciones significativas, por lo cual estos resultados sugieren que el modelo de la tabla 4.39 representa correctamente la correlación dinámica entre las variables.

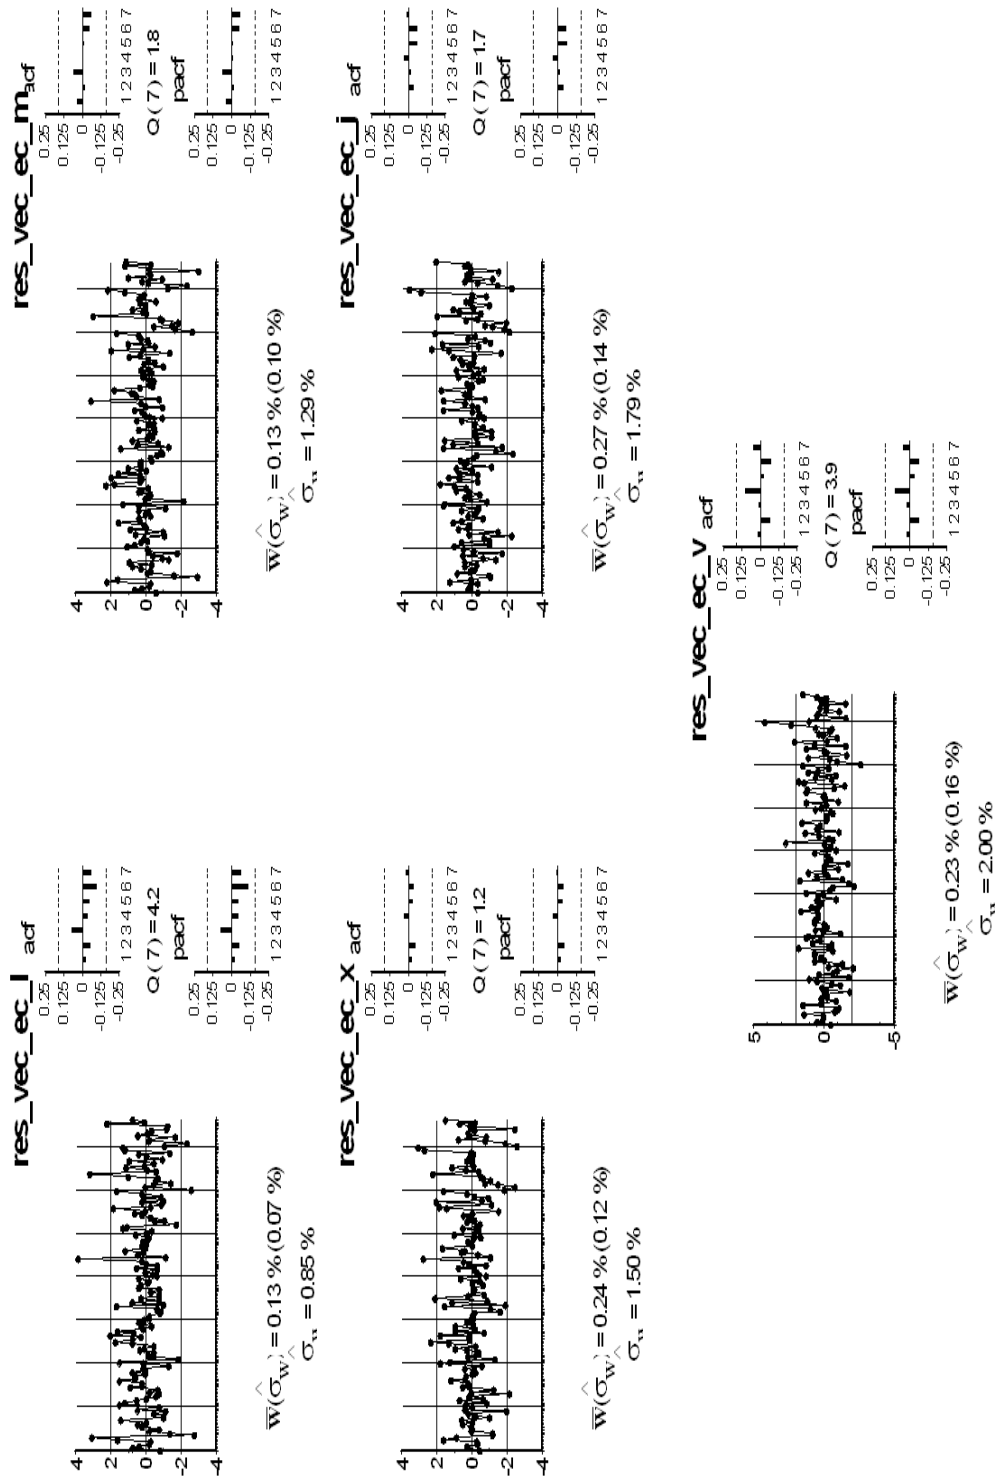


Gráfico 4.18: Banesto: Residuos del VEC(2)

Tabla 4.40: Banesto: Función de correlación cruzada residual del VEC(2)

Retardos	r_{11}	r_{12}	r_{13}	r_{14}	r_{15}
1	-0,025	0,032	0,002	0,018	0,019
2	-0,051	-0,044	-0,066	-0,043	-0,077
3	0,076	0,038	0,000	-0,015	0,019
4	-0,040	-0,035	0,036	0,031	0,013
5	-0,051	-0,040	-0,085	-0,022	-0,038
	r_{21}	r_{22}	r_{23}	r_{24}	r_{25}
1	-0,021	0,038	0,005	0,024	0,032
2	-0,050	-0,016	-0,038	-0,017	-0,063
3	0,098	0,062	0,027	0,023	0,036
4	0,021	-0,005	0,052	0,060	0,039
5	-0,014	-0,010	-0,018	0,029	0,020
	r_{31}	r_{32}	r_{33}	r_{34}	r_{35}
1	-0,021	0,016	-0,028	-0,001	0,009
2	-0,044	-0,025	-0,048	-0,031	-0,064
3	0,090	0,045	-0,003	-0,014	0,003
4	0,035	0,001	0,036	0,059	0,065
5	-0,027	-0,056	-0,032	0,000	-0,020
	r_{41}	r_{42}	r_{43}	r_{44}	r_{45}
1	-0,025	-0,017	-0,035	-0,006	0,006
2	-0,051	-0,034	-0,038	-0,042	-0,068
3	0,105	0,067	0,010	-0,018	0,000
4	0,001	-0,032	0,001	0,031	0,024
5	-0,102	-0,137	-0,077	-0,062	-0,055
	r_{51}	r_{52}	r_{53}	r_{54}	r_{55}
1	-0,052	-0,030	-0,005	0,008	0,020
2	-0,040	-0,007	-0,008	-0,019	-0,068
3	0,097	0,078	0,021	-0,010	0,013
4	0,081	0,073	0,117	0,147	0,102
5	-0,056	-0,074	-0,012	-0,013	-0,026

DT = $\frac{2}{\sqrt{T}} = 0,162$. En * significativos al 95 %.

Se necesita ortogonalizar el VEC, para representar de forma correcta el modelo periódico. Para conseguir la matriz A_0 con la que se ortogonaliza el modelo, se utiliza la matriz 4.18.

$$A_0 = \begin{pmatrix} 1 & 0 & 0 & 0 & 0 \\ -1,27 & 1 & 0 & 0 & 0 \\ 0,16 & -1,10 & 1 & 0 & 0 \\ 0,14 & 0,01 & -1,15 & 1 & 0 \\ 0,01 & -0,22 & 0,77 & -1,42 & 1 \end{pmatrix} \quad (4.19)$$

Premultiplicando el modelo de la tabla 4.39 por la matriz 4.19 se obtiene el modelo ortogonalizado que representa el modelo periódico, el cual se presenta en la tabla 4.41.

Tabla 4.41: Banesto: Modelo VEC(2) ortogonalizado

Variable dependiente	Ecuaciones				
	∇l_t	∇m_t	∇x_t	∇j_t	∇v_t
μ					0,0020
$ecm1_{t-1}$	1,14	-0,49	0,088	0,13	-0,98
$ecm2_{t-1}$	1,34	-0,45	-0,21	-0,89	0,48
$ecm3_{t-1}$	1,19	-0,43	-0,98	0,18	-0,22
$ecm4_{t-1}$	1,12	-1,42	0,18	0,16	0,012
∇l_t		1,27	-0,16	-0,14	-0,011
∇m_t			1,10	-0,012	0,22
∇x_t				1,15	-0,77
∇j_t					1,42
∇l_{t-1}	0,17	-0,018	-0,18	0,026	-0,040
∇j_{t-1}		-0,11	0,12	0,11	-0,13
∇v_{t-1}	-0,14	0,18	-0,023	-0,19	0,23
∇l_{t-2}			-0,16	-0,034	0,18
∇m_{t-2}					-0,43
∇x_{t-2}		-0,10	0,11	-0,0012	0,30
∇j_{t-2}				0,13	-0,18
∇v_{t-2}	-0,19	0,080	0,058	-0,11	0,22

4.A.10 Endesa

4.A.10.1 Relaciones de cointegración

La existencia de estas cuatro relaciones de cointegración se comprueba en la tabla 4.42

Tabla 4.42: Endesa: Test de cointegración, método de Engle-Granger

Variable dependiente	$p = 0$
$ecm1_t$	-11,34
$ecm2_t$	-11,66
$ecm3_t$	-12,00
$ecm4_t$	-12,23

Valor crítico(95 %):-5,28
(Phillips y Ouliaris (1990)).

En el gráfico 4.19 aparecen los residuos de estas relaciones de cointegración. En ellos se aprecia el carácter estacionario de éstas.

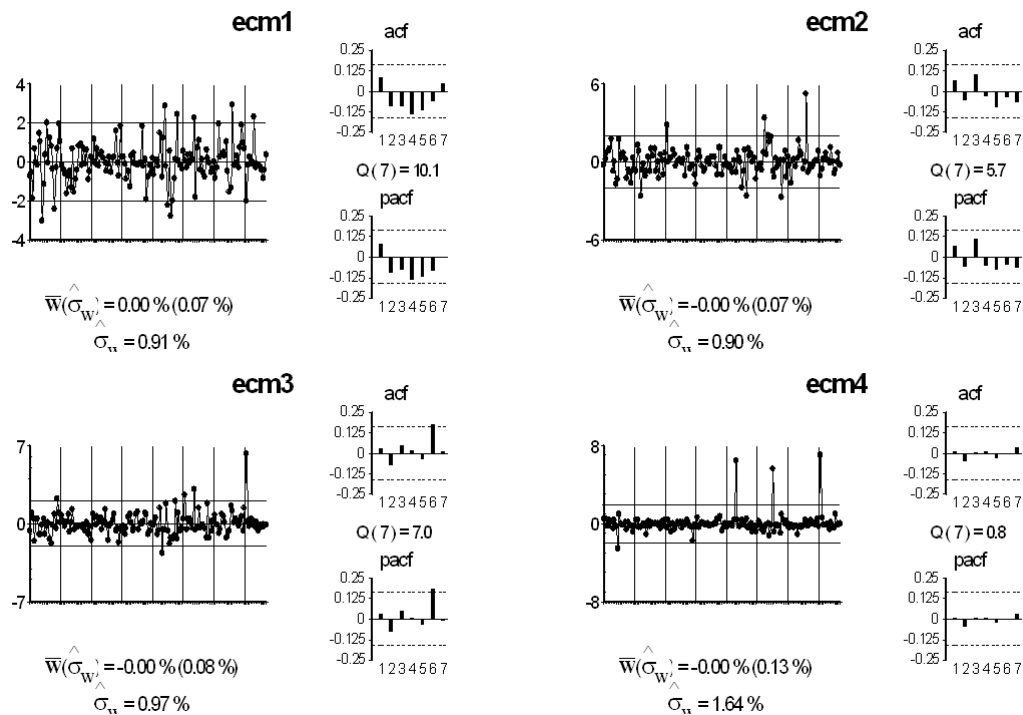


Gráfico 4.19: Endesa: Relaciones de cointegración

4.A.10.2 Estimación modelo VEC

Se estiman todos los parámetros de forma conjunta por mínimos cuadrados generalizados, salvo los de las relaciones de cointegración, que se restringen. Los

resultados aparecen en la tabla 4.43.

Tabla 4.43: Endesa: Estimación del VEC(1)

Variable dependiente	Ecuaciones ^a				
	∇l_t	∇m_t	∇x_t	∇j_t	∇v_t
μ			0,002 (0,001)	0,003 (0,001)	0,005 (0,001)
$ecm1_{t-1}$	1,07 (0,08)	1,17 (0,13)	1,19 (0,13)	1,13 (0,10)	
$ecm2_{t-1}$	0,80 (0,10)	0,97 (0,10)	0,96 (0,08)		
$ecm3_{t-1}$	0,77 (0,09)	1,00 (0,07)			
$ecm4_{t-1}$	0,96 (0,06)				
∇l_{t-1}		-0,086 (0,039)	-0,078 (0,040)	-0,051 (0,029)	
∇m_{t-1}	-0,10 (0,05)			-0,036 (0,025)	
∇j_{t-1}	0,11 (0,06)				-0,21 (0,08)
∇v_{t-1}					0,17 (0,08)

^aLa tabla muestra los coeficientes estimados del modelo VEC donde cada columna representa una ecuación del mismo. Entre paréntesis se presentan las desviaciones típicas.

La matriz de covarianzas se presenta en (4.20).

$$\Sigma_u = \begin{pmatrix} 1,03E-04 & 1,34E-04 & 1,24E-04 & 1,34E-04 & 1,51E-04 \\ 1,34E-04 & 4,26E-04 & 4,56E-04 & 4,51E-04 & 4,57E-04 \\ 1,24E-04 & 4,56E-04 & 5,80E-04 & 5,78E-04 & 5,84E-04 \\ 1,34E-04 & 4,51E-04 & 5,78E-04 & 6,57E-04 & 6,88E-04 \\ 1,51E-04 & 4,57E-04 & 5,84E-04 & 6,88E-04 & 7,98E-04 \end{pmatrix} \quad (4.20)$$

En la tabla 4.44 se presentan las funciones de correlación cruzadas. Aunque una correlación es significativa, se considera que el modelo de la tabla 4.43 representa bien la relación entre las variables. El gráfico 4.20 muestra los residuos del VEC(1).

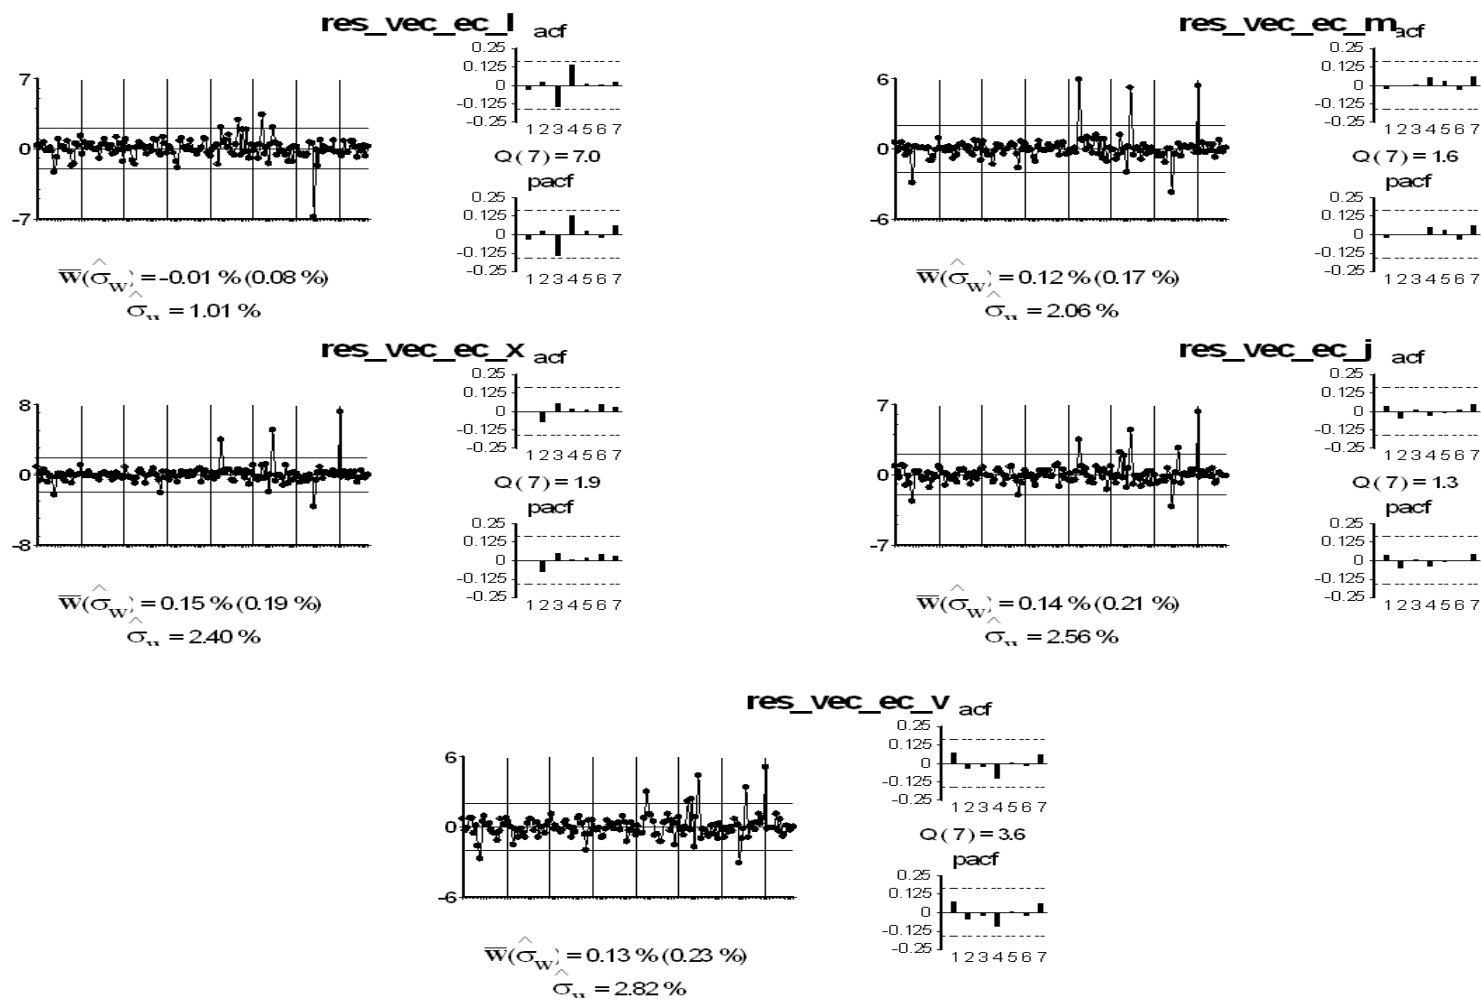


Gráfico 4.20: Endesa: Residuos del VEC(1)

Tabla 4.44: Endesa: Función de correlación cruzada residual del VEC(1)

Retardos	r_{11}	r_{12}	r_{13}	r_{14}	r_{15}
1	-0,030	-0,005	0,015	0,031	0,044
2	0,025	0,022	0,010	0,010	-0,010
3	-0,151	-0,011	0,016	-0,005	-0,040
4	0,138	0,113	0,085	0,051	0,010
5	0,010	0,015	0,041	0,005	-0,004
	r_{21}	r_{22}	r_{23}	r_{24}	r_{25}
1	-0,044	-0,022	0,000	0,024	0,051
2	-0,033	-0,001	-0,038	-0,035	-0,049
3	-0,065	0,002	0,043	0,037	0,063
4	0,054	0,058	0,038	0,020	0,005
5	0,076	0,032	0,041	0,045	0,042
	r_{31}	r_{32}	r_{33}	r_{34}	r_{35}
1	-0,028	-0,029	-0,002	0,023	0,052
2	-0,069	-0,035	-0,075	-0,064	-0,066
3	-0,056	0,015	0,054	0,057	0,074
4	0,009	0,026	0,015	-0,008	-0,016
5	0,100	0,006	0,011	0,020	0,024
	r_{41}	r_{42}	r_{43}	r_{44}	r_{45}
1	-0,035	-0,021	0,014	0,043	0,074
2	-0,044	-0,028	-0,054	-0,050	-0,056
3	-0,145	-0,051	-0,010	0,010	0,027
4	0,002	-0,007	-0,008	-0,033	-0,040
5	0,061	-0,027	-0,009	-0,012	-0,016
	r_{51}	r_{52}	r_{53}	r_{54}	r_{55}
1	-0,051	-0,032	0,006	0,040	0,073
2	-0,008	-0,028	-0,049	-0,038	-0,042
3	-0,216*	-0,091	-0,046	-0,037	-0,029
4	-0,025	-0,053	-0,059	-0,086	-0,102
5	0,063	0,011	0,026	0,020	0,001

DT= $\frac{2}{\sqrt{T}}$ = 0,161. En * significativos al 95 %.

Se necesita ortogonalizar el VEC, para representar de forma correcta el modelo periódico. Para conseguir la matriz A_0 con la que se ortogonaliza el modelo, se utiliza la matriz 4.20.

$$A_0 = \begin{pmatrix} 1 & 0 & 0 & 0 & 0 \\ -1,31 & 1 & 0 & 0 & 0 \\ 0,32 & -1,17 & 1 & 0 & 0 \\ -0,21 & 0,14 & -1,06 & 1 & 0 \\ -0,21 & 0,088 & 0,23 & -1,27 & 1 \end{pmatrix} \quad (4.21)$$

Premultiplicando el modelo de la tabla 4.43 por la matriz 4.21 se obtiene el modelo ortogonalizado que representa el modelo periódico, el cual se presenta en la tabla 4.45.

Tabla 4.45: Endesa: Modelo VEC(1) ortogonalizado

Variable dependiente	Ecuaciones				
	∇l_t	∇m_t	∇x_t	∇j_t	∇v_t
μ			0,0020	0,0009	0,0017
$ecm1_{t-1}$	1,08	-0,24	0,17	-0,18	-1,29
$ecm2_{t-1}$	0,80	-0,080	0,090	-1,06	0,14
$ecm3_{t-1}$	0,77	0,025	-0,96	-0,013	-0,073
$ecm4_{t-1}$	0,96	-1,25	0,31	-0,20	-0,20
∇l_t		1,31	-0,32	0,21	0,21
∇m_t			1,17	-0,14	-0,088
∇x_t				1,06	-0,23
∇j_t					1,27
∇l_{t-1}	-0,086	0,023	0,020	0,039	
∇m_{t-1}	-0,10	0,13	-0,033	-0,014	0,068
∇j_{t-1}	0,11	-0,15	0,036	-0,023	-0,24
∇v_{t-1}					0,17

4.A.11 Enagas

4.A.11.1 Relaciones de cointegración

En la tabla 4.46 se comprueba la existencia de las relaciones de cointegración.

Tabla 4.46: Enagas: Test de cointegración, método de Engle-Granger

Variable dependiente	$p = 0$
$ecm1_t$	-12,99
$ecm2_t$	-13,11
$ecm3_t$	-12,26
$ecm4_t$	-13,74

Valor crítico(95 %):-5,28
(Phillips y Ouliaris (1990)).

Los gráfico de los residuos de estas relaciones de cointegración se presentan en el gráfico 4.21 , y en ellos se observa el carácter estacionario de éstas.

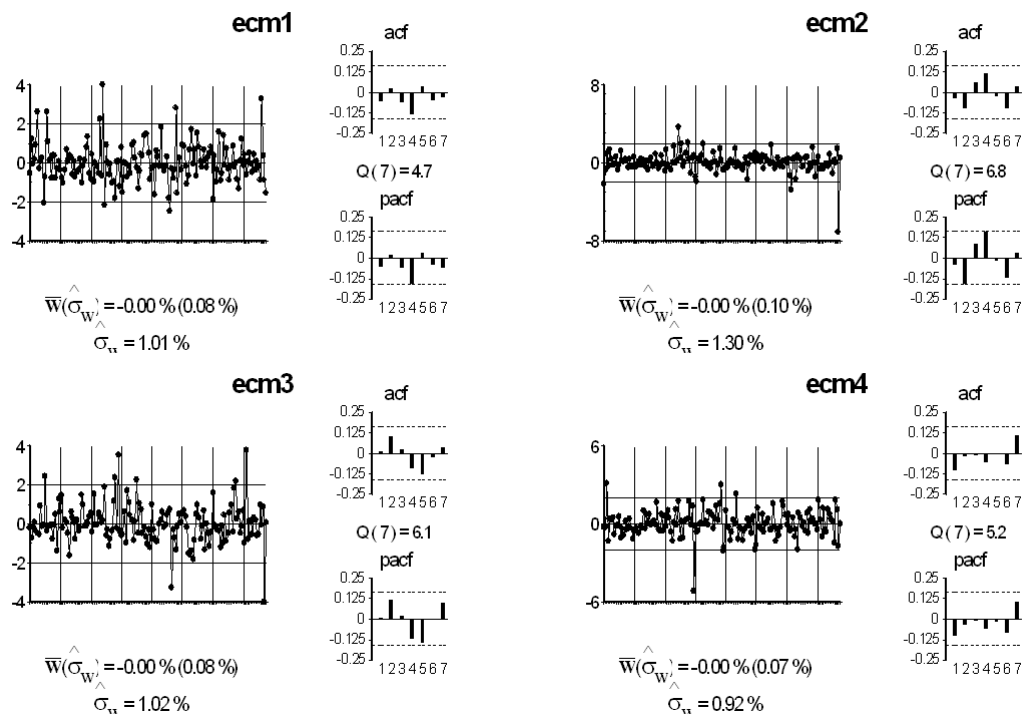


Gráfico 4.21: Enagas: Relaciones de cointegración

4.A.11.2 Estimación modelo VEC

Se estiman todos los parámetros de forma conjunta por mínimos cuadrados generalizados, menos los de las relaciones de cointegración, que se restringen. Los resultados aparecen en la tabla 4.47.

Tabla 4.47: Enagas: Estimación del VEC(2)

Variable dependiente	Ecuaciones ^a				
	∇l_t	∇m_t	∇x_t	∇j_t	∇v_t
μ	0,001 (0,001)	0,002 (0,001)	0,002 (0,001)	0,003 (0,002)	0,006 (0,002)
$ecm1_{t-1}$	0,99 (0,11)	0,96 (0,12)	1,13 (0,12)	1,18 (0,12)	0,25 (0,19)
$ecm2_{t-1}$	0,91 (0,11)	0,82 (0,13)	0,90 (0,14)		-0,19 (0,13)
$ecm3_{t-1}$	0,83 (0,09)	0,74 (0,10)			
$ecm4_{t-1}$	0,77 (0,13)	-0,46 (0,17)	-0,29 (0,18)	-0,20 (0,16)	
∇l_{t-1}			0,27 (0,08)	0,36 (0,18)	0,39 (0,21)
∇m_{t-1}				-0,29 (0,14)	-0,42 (0,19)
∇x_{t-1}	0,053 (0,039)			0,12 (0,10)	0,20 (0,15)
∇j_{t-1}					-0,20 (0,12)
∇v_{t-1}	0,065 (0,086)	0,22 (0,10)	0,061 (0,098)	0,11 (0,11)	0,18 (0,12)
∇j_{t-2}				0,15 (0,05)	
∇v_{t-2}	-0,087 (0,036)	-0,063 (0,047)	-0,29 (0,09)	-0,48 (0,15)	-0,30 (0,15)

^aLa tabla muestra los coeficientes estimados del modelo VEC donde cada columna representa una ecuación del mismo. Entre paréntesis se presentan las desviaciones típicas.

La matriz de covarianzas se presenta en (4.22).

$$\Sigma_u = \begin{pmatrix} 8,68E-05 & 1,03E-04 & 9,05E-05 & 9,35E-05 & 8,96E-05 \\ 1,03E-04 & 1,93E-04 & 1,94E-04 & 2,08E-04 & 2,18E-04 \\ 9,05E-05 & 1,94E-04 & 2,84E-04 & 3,08E-04 & 2,98E-04 \\ 9,35E-05 & 2,08E-04 & 3,08E-04 & 4,27E-04 & 4,37E-04 \\ 8,96E-05 & 2,18E-04 & 2,98E-04 & 4,37E-04 & 5,49E-04 \end{pmatrix} \quad (4.22)$$

Los residuos del VEC(2) aparecen en el gráfico 4.22 y en la tabla 4.48 la función de correlación cruzada. En ella se aprecia que ninguna de las correlaciones es significativa. Estos resultados sugieren que el modelo de la tabla 4.47 representa correctamente las variables.

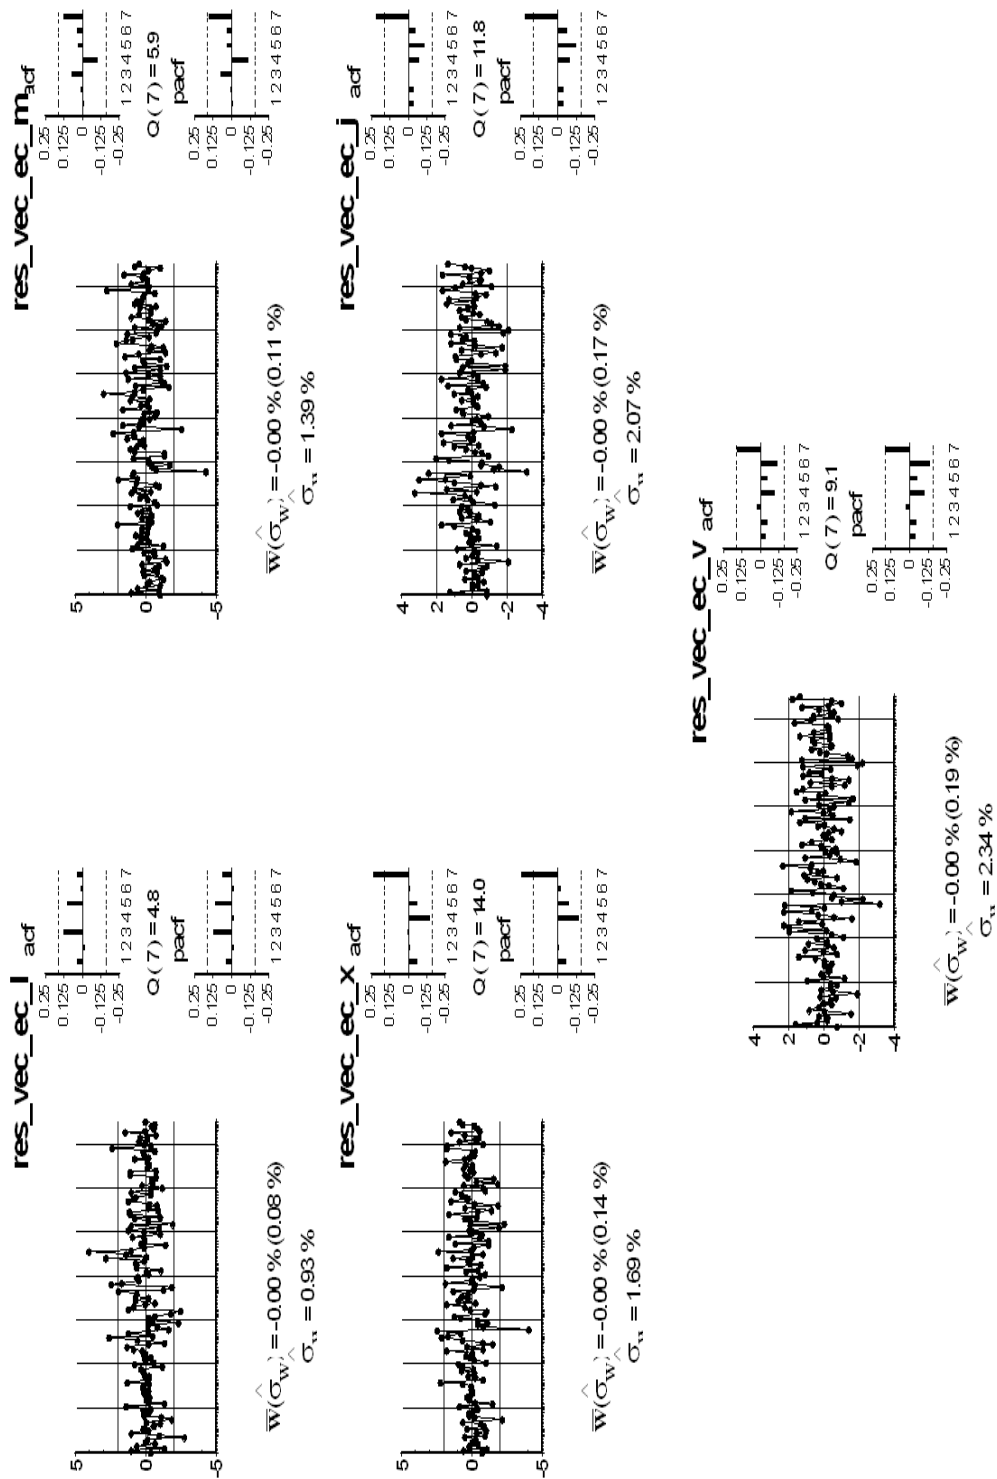


Gráfico 4.22: Enagas: Residuos del VEC(2)

Tabla 4.48: Enagas: Función de correlación cruzada residual del VEC(2)

Retardos	r_{11}	r_{12}	r_{13}	r_{14}	r_{15}
1	0,041	-0,007	-0,007	-0,015	-0,016
2	-0,018	-0,021	-0,021	-0,009	-0,024
3	0,127	0,137	0,104	0,076	0,086
4	-0,003	-0,027	-0,033	-0,019	0,001
5	0,103	0,075	-0,014	-0,001	0,031
	r_{21}	r_{22}	r_{23}	r_{24}	r_{25}
1	0,050	-0,014	-0,022	-0,025	-0,026
2	0,005	0,008	0,000	-0,006	-0,029
3	0,069	0,079	0,031	0,003	0,019
4	-0,101	-0,108	-0,101	-0,071	-0,096
5	0,031	0,035	-0,027	-0,008	0,041
	r_{31}	r_{32}	r_{33}	r_{34}	r_{35}
1	0,017	-0,059	-0,064	-0,065	-0,062
2	-0,035	-0,019	-0,008	-0,010	-0,029
3	0,021	0,046	0,007	-0,008	0,008
4	-0,124	-0,120	-0,151	-0,112	-0,138
5	0,018	0,039	-0,058	-0,020	0,034
	r_{41}	r_{42}	r_{43}	r_{44}	r_{45}
1	-0,006	-0,068	-0,041	-0,040	-0,048
2	-0,062	-0,031	-0,029	-0,040	-0,043
3	0,021	0,016	-0,022	-0,001	0,026
4	-0,085	-0,121	-0,145	-0,077	-0,127
5	-0,043	-0,078	-0,160	-0,114	-0,053
	r_{51}	r_{52}	r_{53}	r_{54}	r_{55}
1	-0,021	-0,070	-0,032	-0,027	-0,037
2	-0,054	-0,013	-0,029	-0,046	-0,044
3	-0,007	0,014	-0,045	-0,011	0,025
4	-0,089	-0,094	-0,084	-0,026	-0,101
5	0,000	-0,054	-0,119	-0,104	-0,047

DT = $\frac{2}{\sqrt{T}} = 0,162$. En * significativos al 95 %.

Se necesita ortogonalizar el VEC, para representar de forma correcta el modelo periódico. Para conseguir la matriz A_0 con la que se ortogonaliza el modelo, se utiliza la matriz 4.22.

$$A_0 = \begin{pmatrix} 1 & 0 & 0 & 0 & 0 \\ -1,17 & 1 & 0 & 0 & 0 \\ 0,48 & -1,27 & 1 & 0 & 0 \\ 0,19 & 0,12 & -1,32 & 1 & 0 \\ 0,39 & -0,58 & 0,52 & -1,20 & 1 \end{pmatrix} \quad (4.23)$$

Premultiplicando el modelo de la tabla 4.47 por la matriz 4.23 se obtiene el modelo ortogonalizado que representa el modelo periódico, el cual aparece en la tabla 4.49.

Tabla 4.49: Enagas: Modelo VEC(2) ortogonalizado

Variable dependiente	Ecuaciones				
	∇l_t	∇m_t	∇x_t	∇j_t	∇v_t
μ	0,0010	0,0008	-0,0001	0,0008	0,0027
$ecm1_{t-1}$	0,99	-0,20	0,39	-0,013	-0,99
$ecm2_{t-1}$	0,91	-0,26	0,30	-1,11	0,59
$ecm3_{t-1}$	0,83	0,23	-0,55	0,25	-0,11
$ecm4_{t-1}$	0,77	-1,36	0,66	0,27	0,66
∇l_t		1,17	-0,48	-0,19	-0,39
∇m_t			1,27	-0,12	0,58
∇x_t				1,32	-0,52
∇j_t					1,20
∇l_{t-1}			0,27	0,057	0,096
∇m_{t-1}				-0,29	-0,076
∇x_{t-1}	-0,053	-0,062	0,025	0,13	0,068
∇j_{t-1}					-0,20
∇v_{t-1}	0,065	0,14	-0,18	0,065	-0,014
∇j_{t-2}				0,15	-0,18
∇v_{t-2}	-0,087	0,039	-0,26	-0,12	0,12

4.A.12 FCC

4.A.12.1 Relaciones de cointegración

En la tabla 4.50 se comprueba la existencia de las relaciones de cointegración.

Tabla 4.50: FCC: Test de cointegración, método de Engle-Granger

Variable dependiente	$p = 0$
$ecm1_t$	-11,90
$ecm2_t$	-14,29
$ecm3_t$	-12,79
$ecm4_t$	-12,49

Valor crítico(95 %):-5,28
(Phillips y Ouliaris (1990)).

Los gráficos de los residuos de estas relaciones de cointegración se presentan en el gráfico 4.23 , y en ellos se observa el carácter estacionario de éstas.

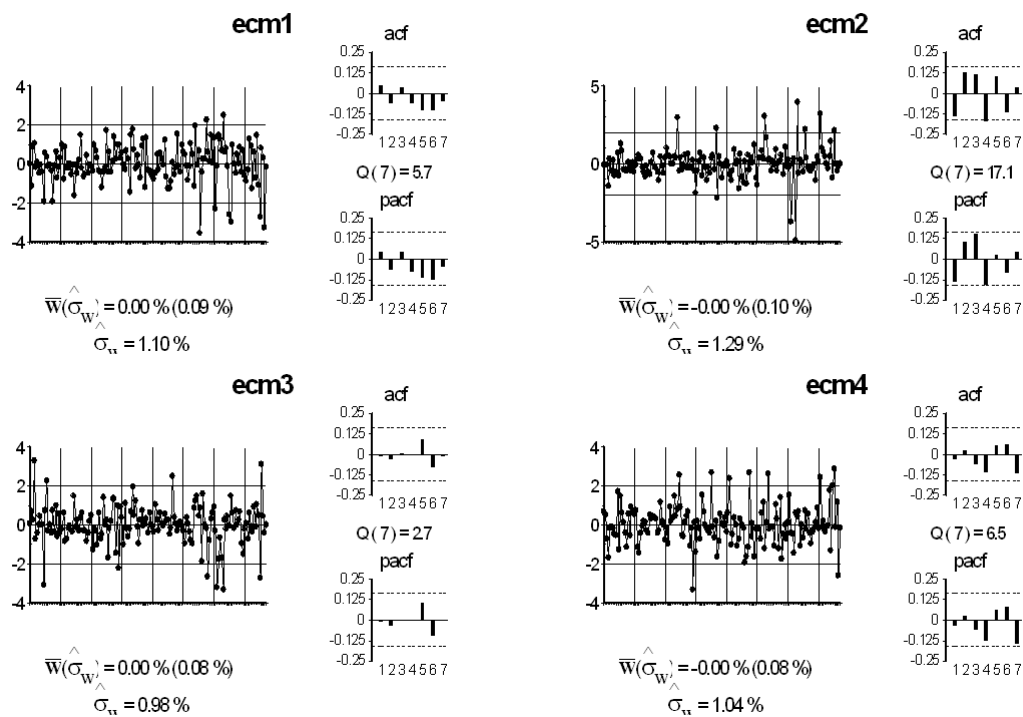


Gráfico 4.23: FCC: Relaciones de cointegración

4.A.12.2 Estimación modelo VEC

Se estiman todos los parámetros de forma conjunta por mínimos cuadrados generalizados, menos los de las relaciones de cointegración, que se restringen. Los

resultados aparecen en la tabla 4.51.

Tabla 4.51: FCC: Estimación del VEC(2)

Variable dependiente	Ecuaciones ^a				
	∇l_t	∇m_t	∇x_t	∇j_t	∇v_t
μ	0,001 (0,001)	0,002 (0,001)	0,003 (0,002)	0,005 (0,002)	0,006 (0,002)
$ecm1_{t-1}$	1,35 (0,12)	1,14 (0,17)	1,10 (0,16)	1,03 (0,14)	
$ecm2_{t-1}$	1,23 (0,13)	1,49 (0,17)	1,60 (0,16)	0,65 (0,21)	0,64 (0,21)
$ecm3_{t-1}$	1,11 (0,11)	1,07 (0,12)		0,34 (0,15)	0,41 (0,18)
$ecm4_{t-1}$	1,39 (0,14)	0,45 (0,18)	0,54 (0,16)	0,39 (0,16)	
∇l_{t-1}	0,15 (0,08)	0,27 (0,10)	0,23 (0,09)		-0,18 (0,11)
∇m_{t-1}				0,30 (0,10)	0,55 (0,13)
∇j_{t-1}		-0,22 (0,08)	-0,17 (0,11)	-0,30 (0,14)	-0,39 (0,15)
∇v_{t-1}	-0,19 (0,10)	-0,074 (0,15)	-0,12 (0,15)	-0,20 (0,17)	-0,12 (0,14)
∇m_{t-2}			-0,077 (0,029)		
∇j_{t-2}			0,14 (0,06)		
∇v_{t-2}	-0,14 (0,07)	-0,23 (0,09)	-0,24 (0,11)	-0,12 (0,09)	-0,18 (0,12)

^aLa tabla muestra los coeficientes estimados del modelo VEC donde cada columna representa una ecuación del mismo. Entre paréntesis se presentan las desviaciones típicas.

La matriz de covarianzas se presenta en (4.24).

$$\Sigma_u = \begin{pmatrix} 1,20E-04 & 1,38E-04 & 1,28E-04 & 1,37E-04 & 1,35E-04 \\ 1,38E-04 & 2,40E-04 & 2,21E-04 & 2,26E-04 & 2,30E-04 \\ 1,28E-04 & 2,21E-04 & 3,06E-04 & 3,36E-04 & 3,26E-04 \\ 1,37E-04 & 2,26E-04 & 3,36E-04 & 5,14E-04 & 5,03E-04 \\ 1,35E-04 & 2,30E-04 & 3,26E-04 & 5,03E-04 & 6,04E-04 \end{pmatrix} \quad (4.24)$$

El gráfico 4.24 muestra los residuos del VEC(2). Por otro lado, en la tabla 4.52 se presentan las funciones de correlación cruzadas. Aunque diez de ellas son significativas, lo son para los retardos cuatro y cinco, por lo que se considera que el modelo de la tabla 4.51 es el adecuado para representar la relación entre las variables.

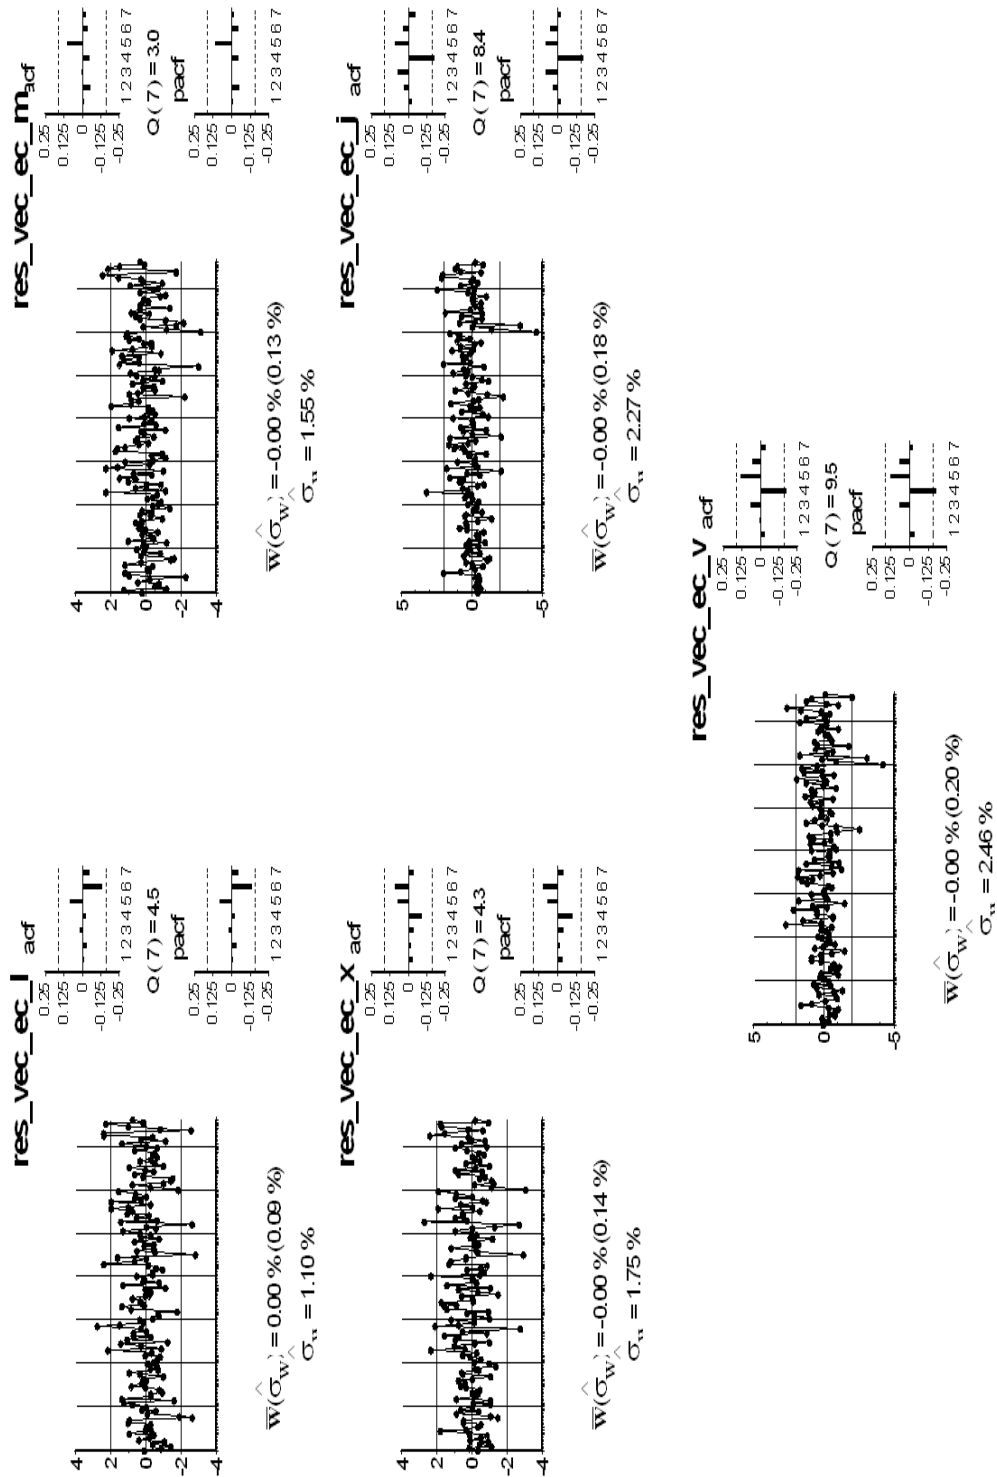


Gráfico 4.24: FCC: Residuos del VEC(2)

Tabla 4.52: FCC: Función de correlación cruzada residual del VEC(2)

Retardos	r_{11}	r_{12}	r_{13}	r_{14}	r_{15}
1	-0,013	-0,004	-0,005	-0,006	0,001
2	-0,032	-0,030	-0,012	0,039	0,012
3	0,015	0,059	0,091	0,096	0,139
4	-0,024	-0,017	-0,008	0,049	0,086
5	0,081	0,148	0,167*	0,189*	0,195*
	r_{21}	r_{22}	r_{23}	r_{24}	r_{25}
1	-0,027	-0,011	-0,001	-0,008	-0,006
2	-0,036	-0,053	-0,031	0,011	-0,007
3	-0,046	0,004	0,036	0,061	0,105
4	-0,025	-0,044	-0,043	0,039	0,042
5	0,026	0,106	0,122	0,165*	0,219*
	r_{31}	r_{32}	r_{33}	r_{34}	r_{35}
1	-0,056	-0,037	-0,035	-0,027	-0,031
2	-0,028	-0,025	-0,018	0,024	0,004
3	-0,122	-0,096	-0,037	0,017	0,047
4	-0,010	-0,033	-0,094	-0,068	-0,058
5	-0,009	0,037	0,073	0,136	0,169*
	r_{41}	r_{42}	r_{43}	r_{44}	r_{45}
1	-0,049	-0,029	-0,044	-0,029	-0,032
2	-0,029	-0,015	-0,009	0,035	0,009
3	-0,045	-0,036	0,038	0,080	0,091
4	-0,094	-0,121	-0,169*	-0,179*	-0,137
5	-0,029	-0,020	0,023	0,093	0,105
	r_{51}	r_{52}	r_{53}	r_{54}	r_{55}
1	-0,052	-0,031	-0,047	-0,030	-0,032
2	-0,028	-0,019	-0,011	0,031	0,005
3	-0,049	-0,060	0,001	0,048	0,067
4	-0,059	-0,111	-0,186*	-0,203*	-0,180*
5	0,016	0,044	0,110	0,142	0,131

DT = $\frac{2}{\sqrt{T}} = 0,161$. En * significativos al 95 %.

Se necesita ortogonalizar el VEC, para representar de forma correcta el modelo periódico. Para conseguir la matriz A_0 con la que se ortogonaliza el modelo, se utiliza la matriz 4.24.

$$A_0 = \begin{pmatrix} 1 & 0 & 0 & 0 & 0 \\ -1,17 & 1 & 0 & 0 & 0 \\ -0,04 & -0,90 & 1 & 0 & 0 \\ -0,14 & 0,29 & -1,25 & 1 & 0 \\ 0,10 & -0,20 & 0,14 & -1,01 & 1 \end{pmatrix} \quad (4.25)$$

Premultiplicando el modelo de la tabla 4.51 por la matriz 4.25 se obtiene el modelo ortogonalizado que representa el modelo periódico, el cual se presenta en la tabla 4.53.

Tabla 4.53: FCC: Modelo VEC(2) ortogonalizado

Variable dependiente	Ecuaciones				
	∇l_t	∇m_t	∇x_t	∇j_t	∇v_t
μ	0,0010	0,0009	0,0012	0,0017	0,0011
$ecm1_{t-1}$	1,35	-0,39	0,016	-0,19	-0,98
$ecm2_{t-1}$	1,24	0,085	0,21	-1,08	0,038
$ecm3_{t-1}$	1,11	-0,19	-1,01	0,49	-0,024
$ecm4_{t-1}$	1,39	-1,13	0,075	-0,34	-0,26
∇l_t		1,14	0,040	0,14	-0,10
∇m_t			0,90	-0,29	0,20
∇x_t				1,25	-0,14
∇j_t					1,01
∇l_{t-1}	0,15	0,091	-0,020	-0,21	-0,18
∇m_{t-1}				0,30	0,25
∇j_{t-1}		-0,22	0,027	-0,15	-0,069
∇v_{t-1}	-0,19	0,15	-0,050	-0,040	0,055
∇m_{t-2}			-0,077	0,096	-0,011
∇j_{t-2}			0,14	-0,17	0,019
∇v_{t-2}	-0,14	-0,065	-0,033	0,13	-0,058

4.A.13 Ferrovial

4.A.13.1 Relaciones de cointegración

En la tabla 4.54 se muestra la existencia de las relaciones de cointegración.

Tabla 4.54: Ferrovial: Test de cointegración, método de Engle-Granger

Variable dependiente	$p = 0$
$ecm1_t$	-10,26
$ecm2_t$	-13,31
$ecm3_t$	-10,54
$ecm4_t$	-13,94

Valor crítico(95 %):-5,28
(Phillips y Ouliaris (1990)).

Los gráficos de los residuos de estas relaciones de cointegración se presentan en el gráfico 4.25 , y en ellos se observa el carácter estacionario de éstas.

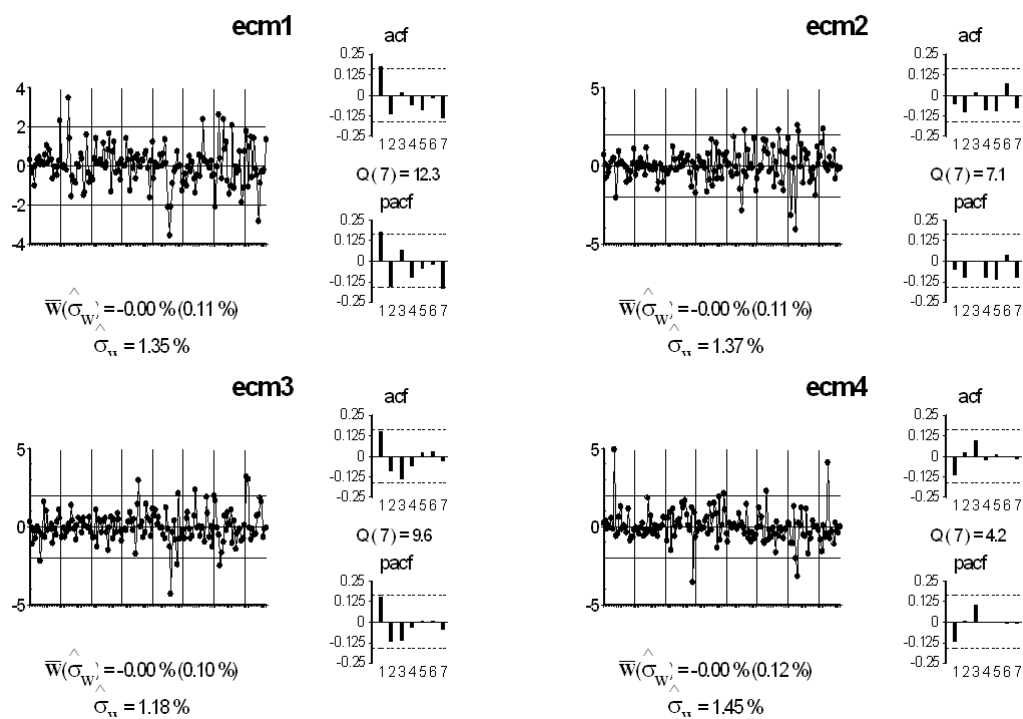


Gráfico 4.25: Ferrovial: Relaciones de cointegración

4.A.13.2 Estimación modelo VEC

Se estiman todos los parámetros de forma conjunta por mínimos cuadrados generalizados, menos los de las relaciones de cointegración, que se restringen. Los

resultados aparecen en la tabla 4.55.

Tabla 4.55: Ferrovial: Estimación del VEC(2)

Variable dependiente	Ecuaciones ^a				
	∇l_t	∇m_t	∇x_t	∇j_t	∇v_t
μ	0,002 (0,001)	0,002 (0,002)	0,004 (0,002)	0,006 (0,002)	0,007 (0,003)
$ecm1_{t-1}$	1,26 (0,11)	1,30 (0,18)	1,50 (0,19)	1,46 (0,23)	0,74 (0,27)
$ecm2_{t-1}$	1,21 (0,13)	1,50 (0,21)	1,93 (0,21)	0,61 (0,26)	0,71 (0,30)
$ecm3_{t-1}$	0,97 (0,11)	0,99 (0,13)			
$ecm4_{t-1}$	1,27 (0,14)	0,22 (0,17)	0,34 (0,12)		
∇l_{t-1}	0,14 (0,09)	0,31 (0,12)	0,36 (0,10)	0,14 (0,07)	
∇m_{t-1}	-0,088 (0,067)		-0,24 (0,08)	-0,082 (0,066)	
∇x_{t-1}	0,11 (0,06)		0,41 (0,11)	0,22 (0,14)	0,23 (0,10)
∇j_{t-1}			-0,15 (0,08)		
∇v_{t-1}	-0,20 (0,10)	-0,29 (0,15)	-0,43 (0,14)	-0,34 (0,17)	-0,45 (0,22)
∇l_{t-2}		0,068 (0,032)			
∇x_{t-2}			0,12 (0,05)	0,14 (0,08)	0,17 (0,10)
∇v_{t-2}	-0,14 (0,07)	-0,29 (0,11)	-0,34 (0,11)	-0,25 (0,13)	-0,24 (0,15)

^aLa tabla muestra los coeficientes estimados del modelo VEC donde cada columna representa una ecuación del mismo. Entre paréntesis se presentan las desviaciones típicas.

La matriz de covarianzas se presenta en (4.26).

$$\Sigma_u = \begin{pmatrix} 1,53E-04 & 2,10E-04 & 2,01E-04 & 2,15E-04 & 1,93E-04 \\ 2,10E-04 & 4,62E-04 & 4,34E-04 & 4,56E-04 & 4,41E-04 \\ 2,01E-04 & 4,34E-04 & 5,29E-04 & 5,64E-04 & 5,57E-04 \\ 2,15E-04 & 4,56E-04 & 5,64E-04 & 7,80E-04 & 8,02E-04 \\ 1,93E-04 & 4,41E-04 & 5,57E-04 & 8,02E-04 & 9,95E-04 \end{pmatrix} \quad (4.26)$$

Los residuos del VEC(2) aparecen en el gráfico 4.26. Por otro lado, en la tabla 4.56 se presentan los valores de la función de correlación cruzada. En ella se aprecia que ninguna correlación es estadísticamente distinta de 0, así que el modelo de la tabla 4.55 representa de forma adecuada la correlación dinámica entre las variables.

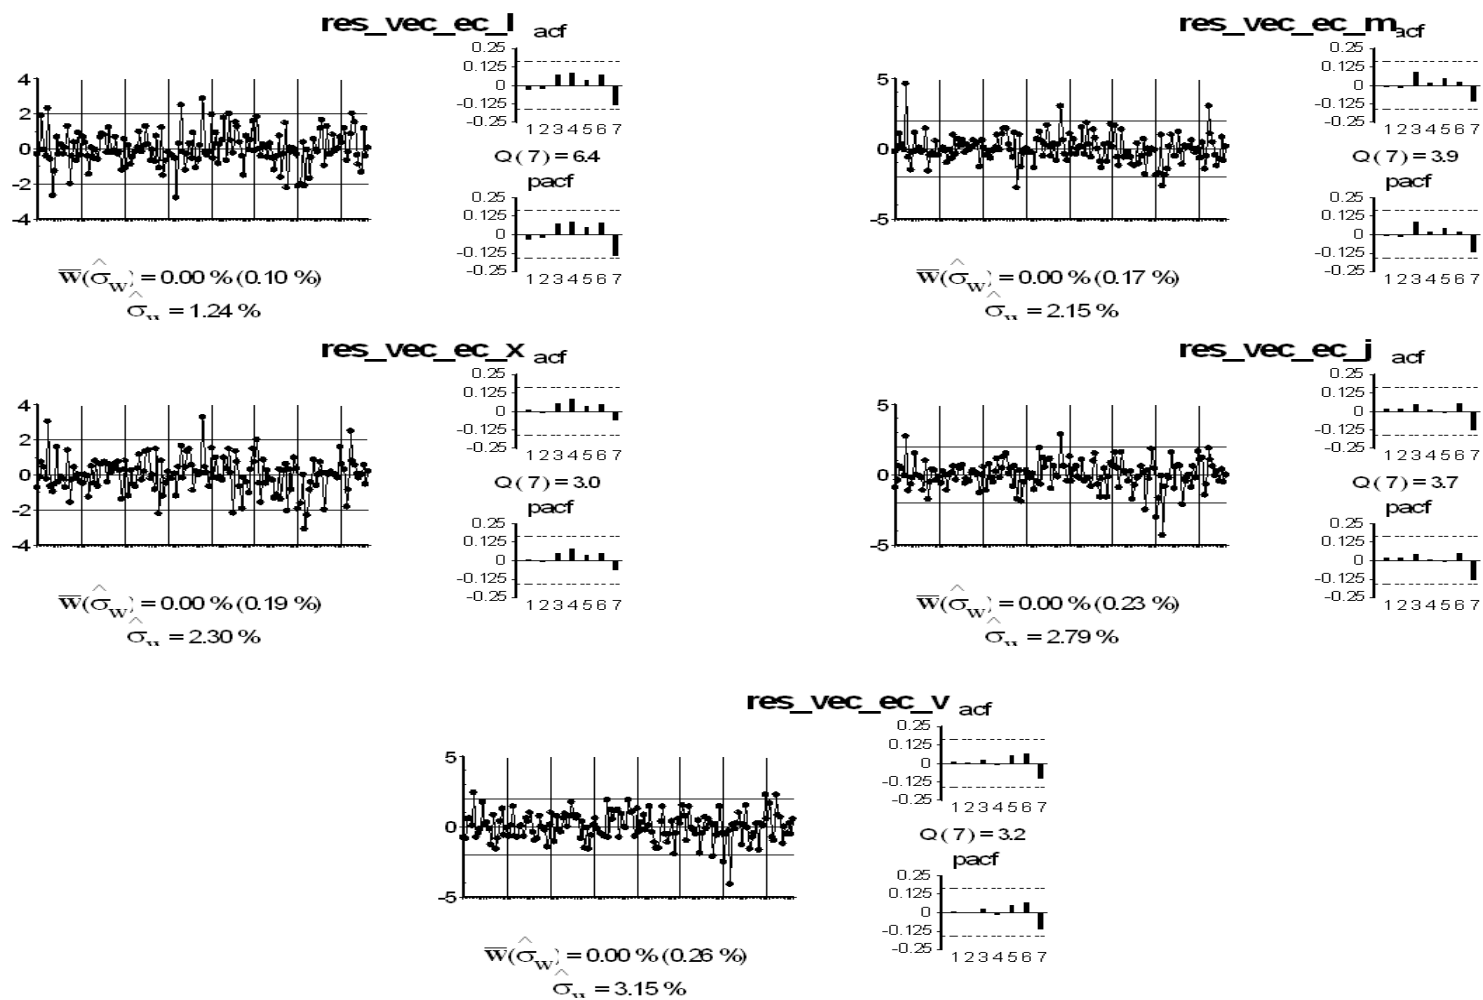


Gráfico 4.26: Ferrovial: Residuos del VEC(2)

Tabla 4.56: Ferrovial: Función de correlación cruzada residual del VEC(2)

Retardos	r_{11}	r_{12}	r_{13}	r_{14}	r_{15}
1	-0,031	-0,006	0,002	0,007	0,004
2	-0,025	0,000	0,004	0,016	0,008
3	0,074	0,023	-0,005	-0,011	-0,024
4	0,087	-0,001	0,017	0,022	-0,013
5	0,043	0,018	0,020	0,031	0,054
	r_{21}	r_{22}	r_{23}	r_{24}	r_{25}
1	-0,049	-0,008	0,001	0,008	0,002
2	-0,048	-0,019	-0,012	-0,013	-0,006
3	0,110	0,089	0,017	0,013	0,012
4	0,089	0,015	0,064	0,051	0,013
5	0,061	0,046	0,056	0,055	0,129
	r_{31}	r_{32}	r_{33}	r_{34}	r_{35}
1	-0,043	0,000	0,007	0,014	0,009
2	-0,055	-0,024	-0,013	-0,003	0,000
3	0,153	0,135	0,056	0,055	0,044
4	0,097	0,066	0,086	0,045	0,005
5	0,021	0,020	0,039	0,041	0,136
	r_{41}	r_{42}	r_{43}	r_{44}	r_{45}
1	-0,023	0,006	0,007	0,015	0,013
2	-0,043	-0,002	-0,003	0,018	0,006
3	0,131	0,130	0,061	0,046	0,037
4	0,066	0,074	0,079	0,012	-0,016
5	0,031	0,007	0,016	-0,008	0,069
	r_{51}	r_{52}	r_{53}	r_{54}	r_{55}
1	-0,031	-0,011	-0,001	0,012	0,013
2	-0,048	-0,003	-0,004	0,029	0,004
3	0,056	0,078	0,032	0,028	0,027
4	0,046	0,094	0,103	0,029	-0,014
5	0,003	0,001	0,039	0,005	0,057

DT= $\frac{2}{\sqrt{T}} = 0,162$. En * significativos al 95 %.

Se necesita ortogonalizar el VEC, para representar de forma correcta el modelo periódico. Para conseguir la matriz A_0 con la que se ortogonaliza el modelo, se utiliza la matriz 4.26.

$$A_0 = \begin{pmatrix} 1 & 0 & 0 & 0 & 0 \\ -1,37 & 1 & 0 & 0 & 0 \\ -0,05 & -0,92 & 1 & 0 & 0 \\ -0,08 & 0,13 & -1,15 & 1 & 0 \\ 0,29 & -0,14 & 0,30 & -1,23 & 1 \end{pmatrix} \quad (4.27)$$

Premultiplicando el modelo de la tabla 4.55 por la matriz 4.27 se obtiene el modelo ortogonalizado que representa el modelo periódico, el cual aparece en la tabla 4.57.

Tabla 4.57: Ferrovial: Modelo VEC(2) ortogonalizado

Variable dependiente	Ecuaciones				
	∇l_t	∇m_t	∇x_t	∇j_t	∇v_t
μ	0,0020	-0,0007	0,0021	0,0015	0,0011
$ecm1_{t-1}$	1,26	-0,43	0,24	-0,19	-0,45
$ecm2_{t-1}$	1,21	-0,17	0,49	-1,51	0,65
$ecm3_{t-1}$	0,97	-0,34	-0,96	0,051	0,13
$ecm4_{t-1}$	1,28	-1,53	0,075	-0,46	0,43
∇l_t		1,37	0,50	0,079	-0,29
∇m_t			0,92	-0,13	0,15
∇x_t				1,15	-0,30
∇j_t					1,23
∇l_{t-1}	0,14	0,12	0,064	-0,24	-0,072
∇m_{t-1}	-0,088	0,12	-0,24	0,20	0,0044
∇x_{t-1}	0,11	-0,15	0,41	-0,26	0,11
∇j_{t-1}		2	-0,16	0,18	-0,046
∇v_{t-1}	-0,20	-0,012	-0,16	0,13	0,28
∇l_{t-2}		0,068	-0,062	0,087	-0,0099
∇x_{t-2}			0,12	0,0008	0,034
∇v_{t-2}	-0,14	-0,10	-0,072	0,12	-0,036

4.A.14 Gamesa

4.A.14.1 Relaciones de cointegración

La existencia de las relaciones de cointegración se muestra en la tabla 4.58.

Tabla 4.58: Gamesa: Test de cointegración, método de Engle-Granger

Variable dependiente	$p = 0$
$ecm1_t$	-12,60
$ecm2_t$	-11,87
$ecm3_t$	-10,84
$ecm4_t$	-12,60

Valor crítico(95 %):-5,28
(Phillips y Ouliaris (1990)).

Los gráficos de los residuos de estas relaciones de cointegración se presentan en el gráfico 4.27 , y en él se observa el carácter estacionario de éstas.

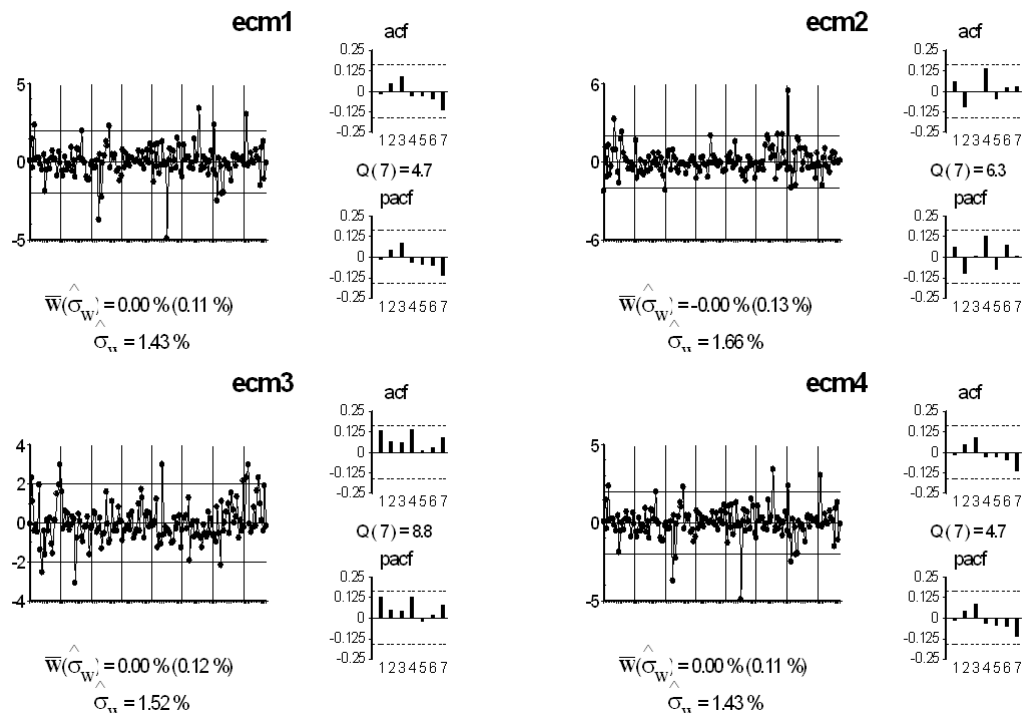


Gráfico 4.27: Gamesa: Relaciones de cointegración

4.A.14.2 Estimación modelo VEC

Se estiman todos los parámetros de forma conjunta por mínimos cuadrados generalizados, salvo los de las relaciones de cointegración, que se restringen. Los

resultados aparecen en la tabla 4.59.

Tabla 4.59: Gamesa: Estimación del VEC(0)

Variable dependiente	Ecuaciones ^a				
	∇l_t	∇m_t	∇x_t	∇j_t	∇v_t
μ	0,001 (0,001)				
$ecm1_{t-1}$	1,05 (0,07)	0,99 (0,10)	0,90 (0,10)	0,93 (0,07)	
$ecm2_{t-1}$	1,01 (0,05)	1,00 (0,07)	0,95 (0,06)		
$ecm3_{t-1}$	0,95 (0,05)	0,91 (0,06)			
$ecm4_{t-1}$	1,03 (0,04)				

^aLa tabla muestra los coeficientes estimados del modelo VEC donde cada columna representa una ecuación del mismo. Entre paréntesis se presentan las desviaciones típicas.

La matriz de covarianzas se presenta en (4.28).

$$\Sigma_u = \begin{pmatrix} 1,43E-04 & 1,80E-04 & 1,48E-04 & 1,60E-04 & 1,73E-04 \\ 1,80E-04 & 4,24E-04 & 4,16E-04 & 4,68E-04 & 4,93E-04 \\ 1,48E-04 & 4,16E-04 & 6,37E-04 & 6,90E-04 & 7,01E-04 \\ 1,60E-04 & 4,68E-04 & 6,90E-04 & 1,01E-03 & 1,08E-03 \\ 1,73E-04 & 4,93E-04 & 7,01E-04 & 1,08E-03 & 1,32E-03 \end{pmatrix} \quad (4.28)$$

El gráfico 4.28 muestra los residuos del VEC(0). Por otro lado, en la tabla 4.60 se presentan las funciones de correlación cruzadas. En ninguna de ellas se aprecian correlaciones significativas, por lo que se considera que el modelo de la tabla 4.59 es apropiado para representar la relación entre las variables.

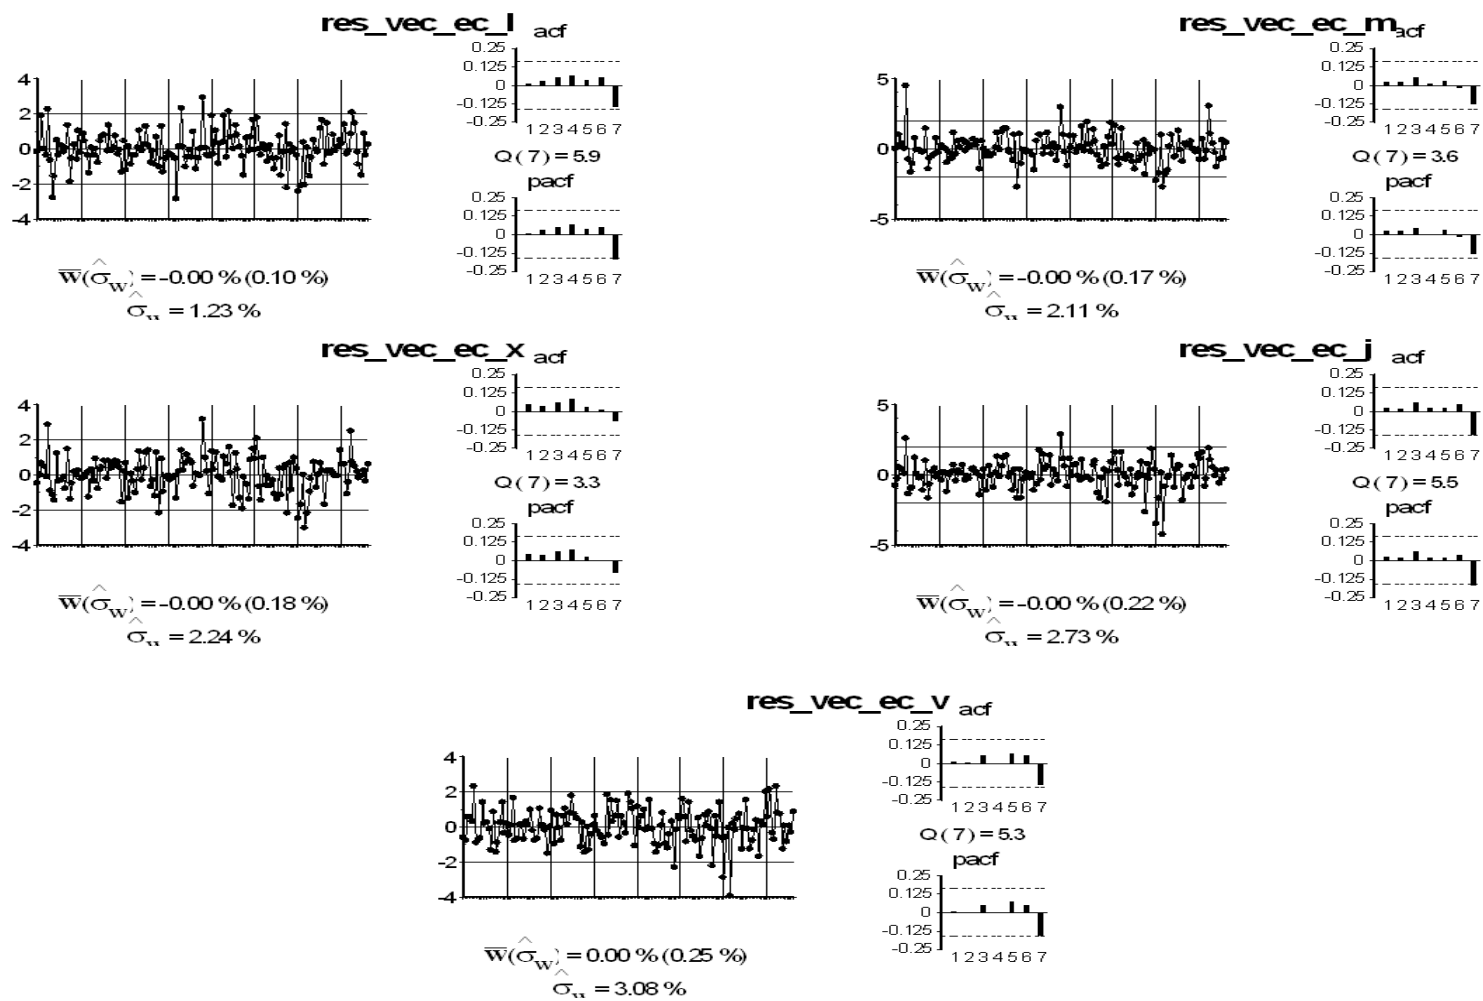


Gráfico 4.28: Gamesa: Residuos del VEC(0)

Tabla 4.60: Gamesa: Función de correlación cruzada residual del VEC(0)

Retardos	r_{11}	r_{12}	r_{13}	r_{14}	r_{15}
1	0,008	0,021	0,026	0,026	0,025
2	0,031	0,029	0,037	0,022	0,012
3	0,056	0,017	0,014	0,003	0,009
4	0,071	-0,007	0,016	0,026	-0,008
5	0,043	-0,008	-0,003	0,025	0,046
	r_{21}	r_{22}	r_{23}	r_{24}	r_{25}
1	0,016	0,029	0,038	0,035	0,031
2	0,048	0,025	0,034	0,012	0,002
3	0,088	0,051	0,044	0,036	0,050
4	0,071	0,008	0,072	0,069	0,033
5	0,073	0,034	0,041	0,062	0,132
	r_{31}	r_{32}	r_{33}	r_{34}	r_{35}
1	0,026	0,034	0,045	0,037	0,033
2	0,055	0,028	0,039	0,016	0,010
3	0,110	0,067	0,063	0,058	0,074
4	0,068	0,050	0,084	0,052	0,014
5	0,034	0,014	0,033	0,064	0,157
	r_{41}	r_{42}	r_{43}	r_{44}	r_{45}
1	0,022	0,026	0,037	0,029	0,027
2	0,045	0,027	0,038	0,020	0,016
3	0,090	0,066	0,073	0,062	0,072
4	0,045	0,066	0,080	0,024	-0,005
5	0,048	0,008	0,021	0,024	0,098
	r_{51}	r_{52}	r_{53}	r_{54}	r_{55}
1	0,001	0,001	0,010	0,011	0,012
2	0,031	0,020	0,026	0,015	0,007
3	0,012	0,021	0,039	0,042	0,053
4	0,026	0,082	0,100	0,042	-0,002
5	0,013	-0,009	0,038	0,024	0,072

DT= $\frac{2}{\sqrt{T}}$ = 0,161. En * significativos al 95 %.

Se necesita ortogonalizar el VEC, para representar de forma correcta el modelo periódico. Para conseguir la matriz A_0 con la que se ortogonaliza el modelo, se utiliza la matriz 4.28.

$$A_0 = \begin{pmatrix} 1 & 0 & 0 & 0 & 0 \\ -1,25 & 1 & 0 & 0 & 0 \\ 0,42 & -1,16 & 1 & 0 & 0 \\ 0,16 & -0,19 & -0,99 & 1 & 0 \\ -0,065 & -0,060 & 0,26 & -1,20 & 1 \end{pmatrix} \quad (4.29)$$

Premultiplicando el modelo de la tabla 4.59 por la matriz 4.29 se obtiene el modelo ortogonalizado que representa el modelo periódico, el cual se muestra en la tabla 4.61.

Tabla 4.61: Gamesa: Modelo VEC(0) ortogonalizado

Variable dependiente	Ecuaciones				
	∇l_t	∇m_t	∇x_t	∇j_t	∇v_t
μ	0,0010	-0,0013	0,0004	0,0002	-0,0001
$ecm1_{t-1}$	1,05	-0,32	0,19	0,0081	-1,01
$ecm2_{t-1}$	1,01	-0,26	0,20	-0,97	0,12
$ecm3_{t-1}$	0,95	-0,28	-0,66	-0,024	-0,12
$ecm4_{t-1}$	1,03	-1,29	0,43	0,16	-0,067
∇l_t		1,25	-0,42	-0,16	0,065
∇m_t			1,16	0,19	0,060
∇x_t				0,99	-0,26
∇j_t					1,20

4.A.15 Gas Natural

4.A.15.1 Relaciones de cointegración

La existencia de las relaciones de cointegración se muestra en la tabla 4.62.

Tabla 4.62: Gas Natural: Test de cointegración, método de Engle-Granger

Variable dependiente	$p = 0$
$ecm1_t$	-12,67
$ecm2_t$	-13,68
$ecm3_t$	-12,16
$ecm4_t$	-13,32

Valor crítico(95 %):-5,28

(Phillips y Ouliaris (1990)).

El gráfico 4.29 muestra los residuos de estas relaciones de cointegración, y en ellos se observa el carácter estacionario de éstas.

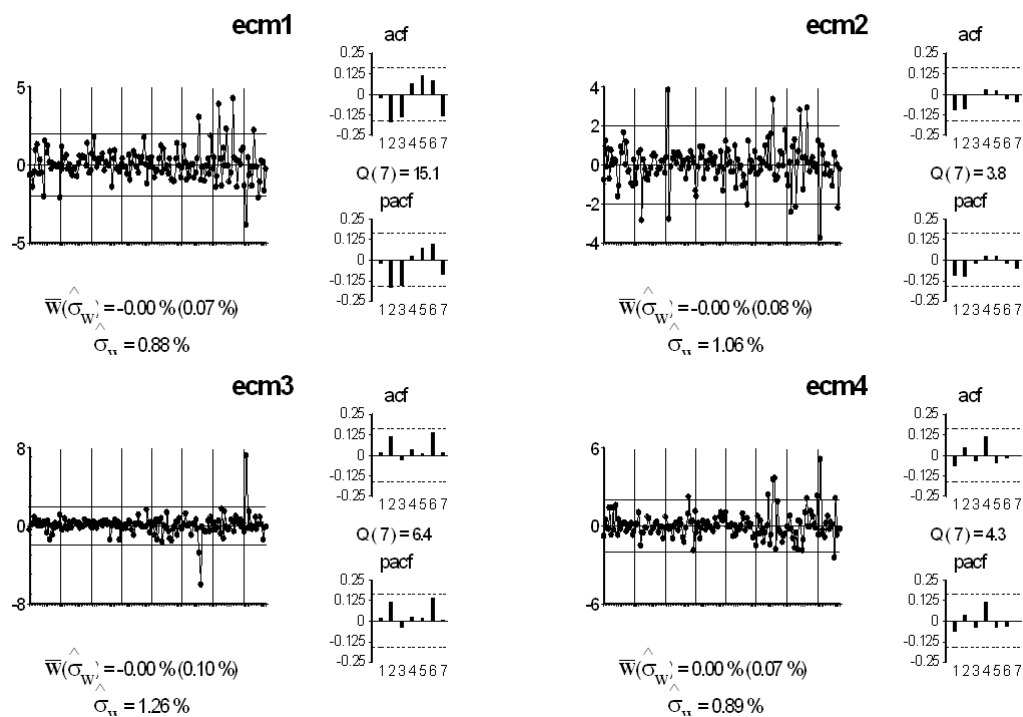


Gráfico 4.29: Gas Natural: Relaciones de cointegración

4.A.15.2 Estimación modelo VEC

Se estiman todos los parámetros de forma conjunta por mínimos cuadrados generalizados, menos los de las relaciones de cointegración, que se restringen. Los resultados aparecen en la tabla 4.63.

Tabla 4.63: Gas Natural: Estimación del VEC(1)

Variable dependiente	Ecuaciones ^a				
	∇l_t	∇m_t	∇x_t	∇j_t	∇v_t
$ecm1_{t-1}$	0,95 (0,13)	0,84 (0,16)	0,85 (0,12)	1,00 (0,07)	
$ecm2_{t-1}$	1,10 (0,11)	1,29 (0,13)	1,09 (0,07)		
$ecm3_{t-1}$	0,89 (0,08)	0,83 (0,08)			
$ecm4_{t-1}$	1,06 (0,09)				
∇l_{t-1}	-0,045 (0,035)	-0,089 (0,045)	0,18 (0,05)		-0,13 (0,05)
∇m_{t-1}			-0,17 (0,07)	-0,070 (0,040)	
∇x_{t-1}	0,20 (0,07)	0,26 (0,08)			
∇j_{t-1}	-0,36 (0,11)	-0,46 (0,14)			
∇v_{t-1}	0,24 (0,10)	0,30 (0,11)			

^aLa tabla muestra los coeficientes estimados del modelo VEC donde cada columna representa una ecuación del mismo. Entre paréntesis se presentan las desviaciones típicas.

La matriz de covarianzas se presenta en (4.30).

$$\Sigma_u = \begin{pmatrix} 6,58E-05 & 8,42E-05 & 7,29E-05 & 7,37E-05 & 6,78E-05 \\ 8,42E-05 & 1,82E-04 & 1,83E-04 & 1,82E-04 & 1,77E-04 \\ 7,29E-05 & 1,83E-04 & 3,13E-04 & 2,97E-04 & 2,77E-04 \\ 7,37E-05 & 1,82E-04 & 2,97E-04 & 3,84E-04 & 4,02E-04 \\ 6,78E-05 & 1,77E-04 & 2,77E-04 & 4,02E-04 & 4,95E-04 \end{pmatrix} \quad (4.30)$$

El gráfico 4.30 muestra los residuos del VEC(1). Por otro lado, en la tabla 4.64 se presentan las funciones de correlación cruzadas. Aunque once de las correlaciones de la tabla son significativas, son para retardos lejanos como el cuarto y el quinto, por lo que se considera que el modelo de la tabla 4.63 representa de forma adecuada la relación dinámica entre las variables.

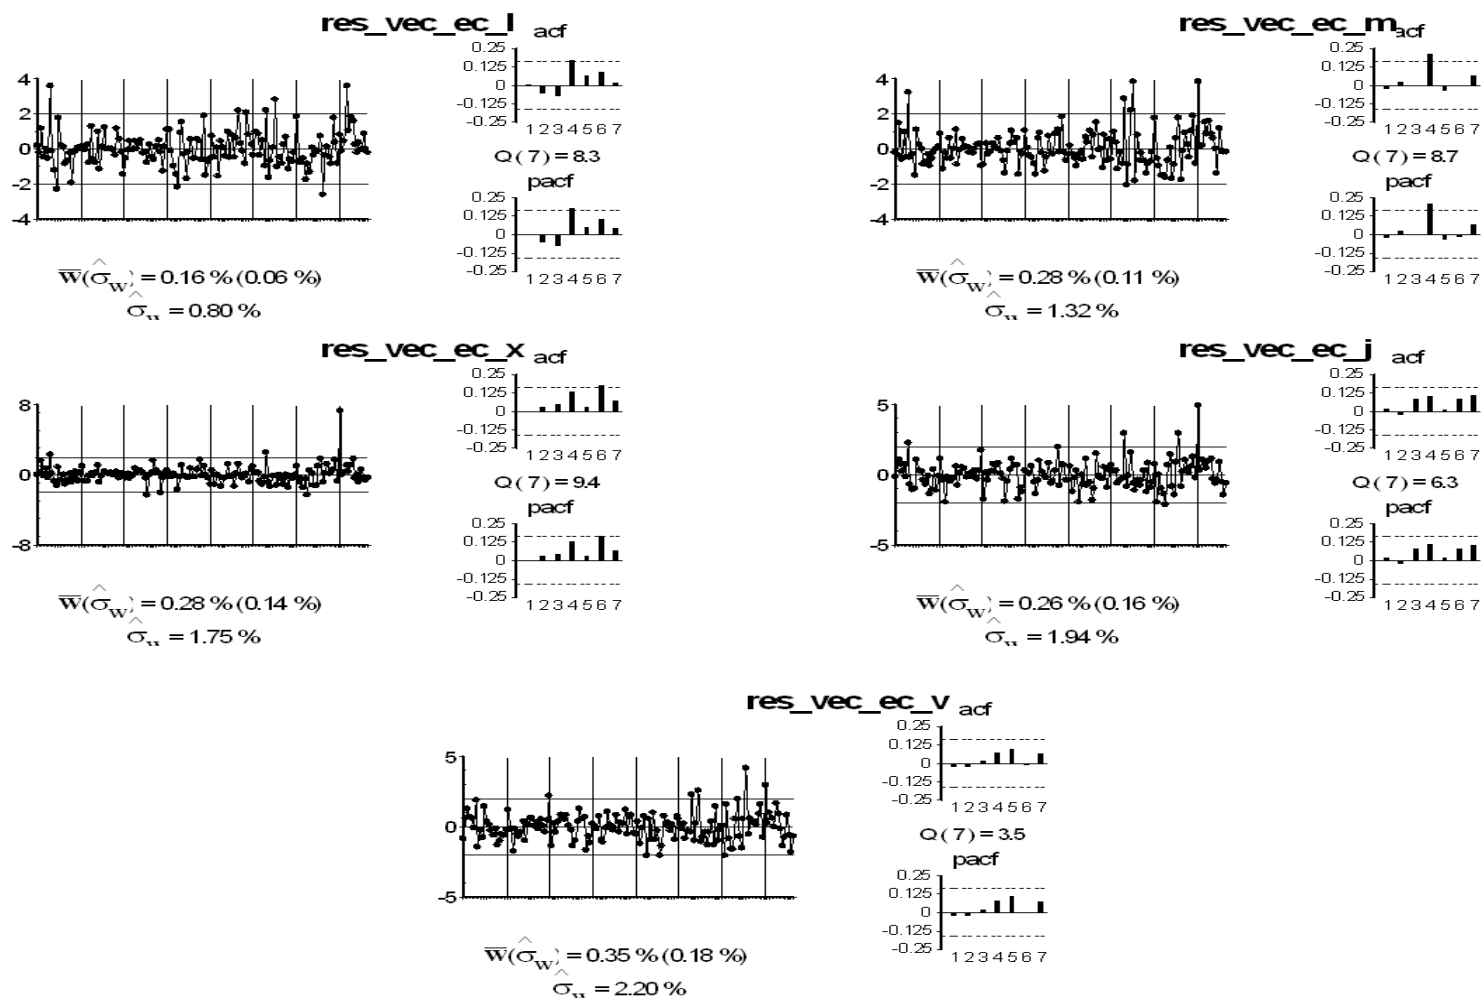


Gráfico 4.30: Gas Natural: Residuos del VEC(1)

Tabla 4.64: Gas Natural: Función de correlación cruzada residual del VEC(1)

Retardos	r_{11}	r_{12}	r_{13}	r_{14}	r_{15}
1	0,004	0,003	-0,025	-0,016	-0,021
2	-0,054	-0,012	-0,020	-0,046	-0,047
3	-0,080	0,000	0,163*	0,082	0,039
4	0,174*	0,206*	0,217*	0,209*	0,167*
5	0,066	0,082	0,128	0,078	0,018
	r_{21}	r_{22}	r_{23}	r_{24}	r_{25}
1	-0,039	-0,026	-0,022	-0,016	-0,026
2	-0,018	0,028	0,006	-0,024	-0,027
3	-0,041	-0,003	0,080	0,093	0,080
4	0,164*	0,215*	0,257*	0,267*	0,230*
5	-0,051	-0,039	0,054	0,039	0,033
	r_{31}	r_{32}	r_{33}	r_{34}	r_{35}
1	-0,022	-0,010	-0,006	-0,013	-0,029
2	0,005	0,035	0,032	-0,023	-0,022
3	0,104	0,041	0,047	0,055	0,054
4	0,012	0,045	0,133	0,149	0,157
5	-0,097	-0,047	0,032	0,011	0,036
	r_{41}	r_{42}	r_{43}	r_{44}	r_{45}
1	-0,024	-0,008	0,034	0,018	-0,006
2	-0,027	0,012	0,032	-0,023	-0,040
3	0,093	0,036	0,077	0,080	0,064
4	-0,018	0,030	0,109	0,108	0,125
5	-0,063	-0,023	0,020	0,014	0,051
	r_{51}	r_{52}	r_{53}	r_{54}	r_{55}
1	-0,068	-0,052	0,015	-0,002	-0,027
2	0,035	0,032	0,051	0,015	-0,022
3	0,047	-0,009	0,047	0,051	0,019
4	-0,056	-0,034	0,045	0,052	0,076
5	-0,086	-0,015	0,051	0,053	0,098

DT = $\frac{2}{\sqrt{T}} = 0,161$. En * significativos al 95 %

Se necesita ortogonalizar el VEC, para representar de forma correcta el modelo periódico. Para conseguir la matriz A_0 con la que se ortogonaliza el modelo, se utiliza la matriz 4.30.

$$A_0 = \begin{pmatrix} 1 & 0 & 0 & 0 & 0 \\ -1,28 & 1 & 0 & 0 & 0 \\ 0,46 & -1,22 & 1 & 0 & 0 \\ -0,01 & -0,10 & -0,88 & 1 & 0 \\ 0,23 & -0,20 & 0,47 & -1,36 & 1 \end{pmatrix} \quad (4.31)$$

Premultiplicando el modelo de la tabla 4.63 por la matriz 4.31 se obtiene el modelo ortogonalizado que representa el modelo periódico, el cual aparece en la tabla 4.65.

Tabla 4.65: Gas Natural: Modelo VEC(1) ortogonalizado

Variable dependiente	Ecuaciones				
	∇l_t	∇m_t	∇x_t	∇j_t	∇v_t
$ecm1_{t-1}$	0,95	-0,37	0,25	0,16	-0,90
$ecm2_{t-1}$	1,10	-0,12	0,016	-1,10	0,51
$ecm3_{t-1}$	0,89	-0,31	-0,61	-0,085	0,040
$ecm4_{t-1}$	1,06	-1,36	0,48	-0,0066	0,24
∇l_t		1,28	-0,46	0,0063	-0,23
∇m_t			1,22	0,097	0,20
∇x_t				0,88	-0,47
∇j_t					1,36
∇l_{t-1}	-0,045	-0,031	0,27	-0,15	-0,038
∇m_{t-1}			-0,17	0,080	0,015
∇x_{t-1}	0,20	0,0093	-0,23	-0,026	-0,0067
∇j_{t-1}	-0,36	0,0008	0,40	0,047	0,0087
∇v_{t-1}	0,24	-0,012	-0,25	-0,030	-0,0035

4.A.16 Iberdrola

4.A.16.1 Relaciones de cointegración

En la tabla 4.66 se muestra la existencia de las relaciones de cointegración.

Tabla 4.66: Iberdrola: Test de cointegración, método de Engle-Granger

Variable dependiente	$p = 0$
$ecm1_t$	-10,60
$ecm2_t$	-13,35
$ecm3_t$	-12,14
$ecm4_t$	-14,34

Valor crítico(95 %):-5,28

(Phillips y Ouliaris (1990)).

Los gráfico de los residuos de estas relaciones de cointegración se presentan en el gráfico 4.31 , y en ellos se observa el carácter estacionario de éstas.

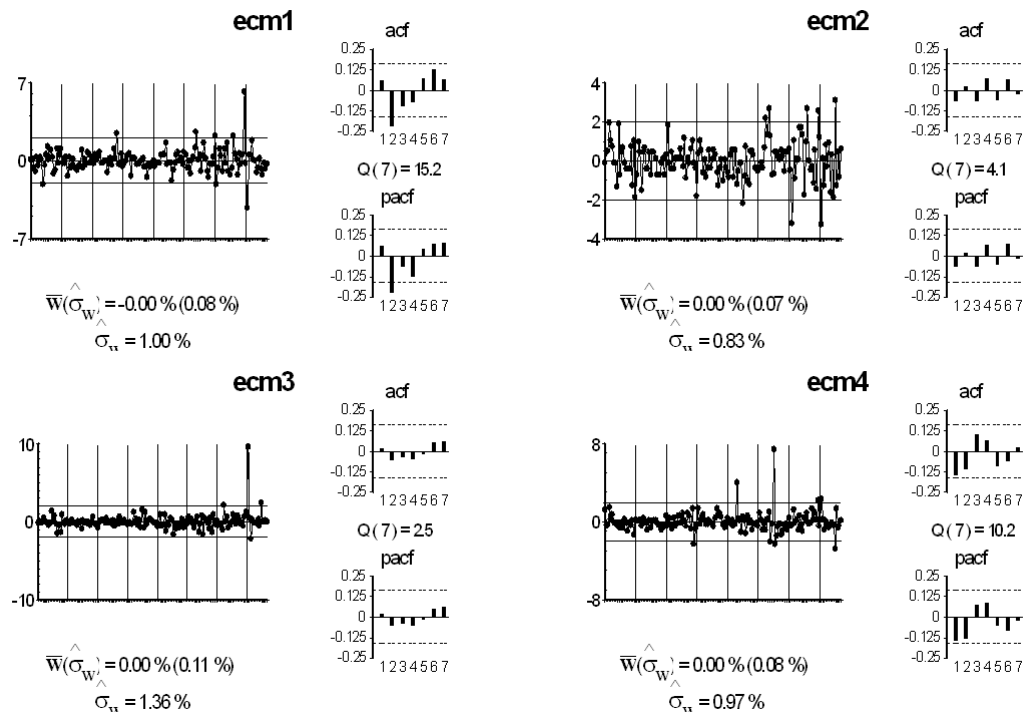


Gráfico 4.31: Iberdrola: Relaciones de cointegración

4.A.16.2 Estimación modelo VEC

Se estiman todos los parámetros de forma conjunta por mínimos cuadrados generalizados, menos los de las relaciones de cointegración, que se restringen. Los resultados aparecen en la tabla 4.67.

Tabla 4.67: Iberdrola: Estimación del VEC(1)

Variable dependiente	Ecuaciones ^a				
	∇l_t	∇m_t	∇x_t	∇j_t	∇v_t
μ				0,001 (0,001)	0,003 (0,001)
$ecm1_{t-1}$	1,15 (0,11)	1,48 (0,18)	2,52 (0,25)	2,25 (0,28)	0,96 (0,33)
$ecm2_{t-1}$	1,11 (0,11)	1,12 (0,16)	1,72 (0,25)	0,72 (0,27)	0,63 (0,33)
$ecm3_{t-1}$	1,03 (0,09)	1,24 (0,14)	0,75 (0,19)	0,63 (0,21)	0,55 (0,25)
$ecm4_{t-1}$	1,07 (0,10)		0,61 (0,18)	0,57 (0,22)	0,44 (0,27)
∇l_{t-1}	-0,10 (0,06)	-0,20 (0,06)			
∇m_{t-1}	0,10 (0,07)	0,19 (0,08)			
∇x_{t-1}			0,28 (0,09)	0,43 (0,09)	0,49 (0,14)
∇j_{t-1}		0,15 (0,07)	0,40 (0,10)		-0,32 (0,14)
∇v_{t-1}	-0,11 (0,07)	-0,39 (0,12)	-1,38 (0,18)	-1,04 (0,20)	-0,66 (0,25)

^aLa tabla muestra los coeficientes estimados del modelo VEC donde cada columna representa una ecuación del mismo. Entre paréntesis se presentan las desviaciones típicas.

La matriz de covarianzas se presenta en (4.32).

$$\Sigma_u = \begin{pmatrix} 6,50E-05 & 8,01E-05 & 7,61E-05 & 6,97E-05 & 7,75E-05 \\ 8,01E-05 & 1,83E-04 & 1,93E-04 & 1,80E-04 & 1,99E-04 \\ 7,61E-05 & 1,93E-04 & 3,27E-04 & 3,24E-04 & 3,22E-04 \\ 6,97E-05 & 1,80E-04 & 3,24E-04 & 3,83E-04 & 4,04E-04 \\ 7,75E-05 & 1,99E-04 & 3,22E-04 & 4,04E-04 & 5,19E-04 \end{pmatrix} \quad (4.32)$$

Los residuos del VEC(1) aparecen en el gráfico 4.32. Por otro lado, en la tabla 4.68 se presentan las funciones de correlación cruzadas. Sólo una de ellas es significativa, por lo que se cree que el modelo de la tabla 4.67 es una forma adecuada de representar la correlación dinámica entre las variables.

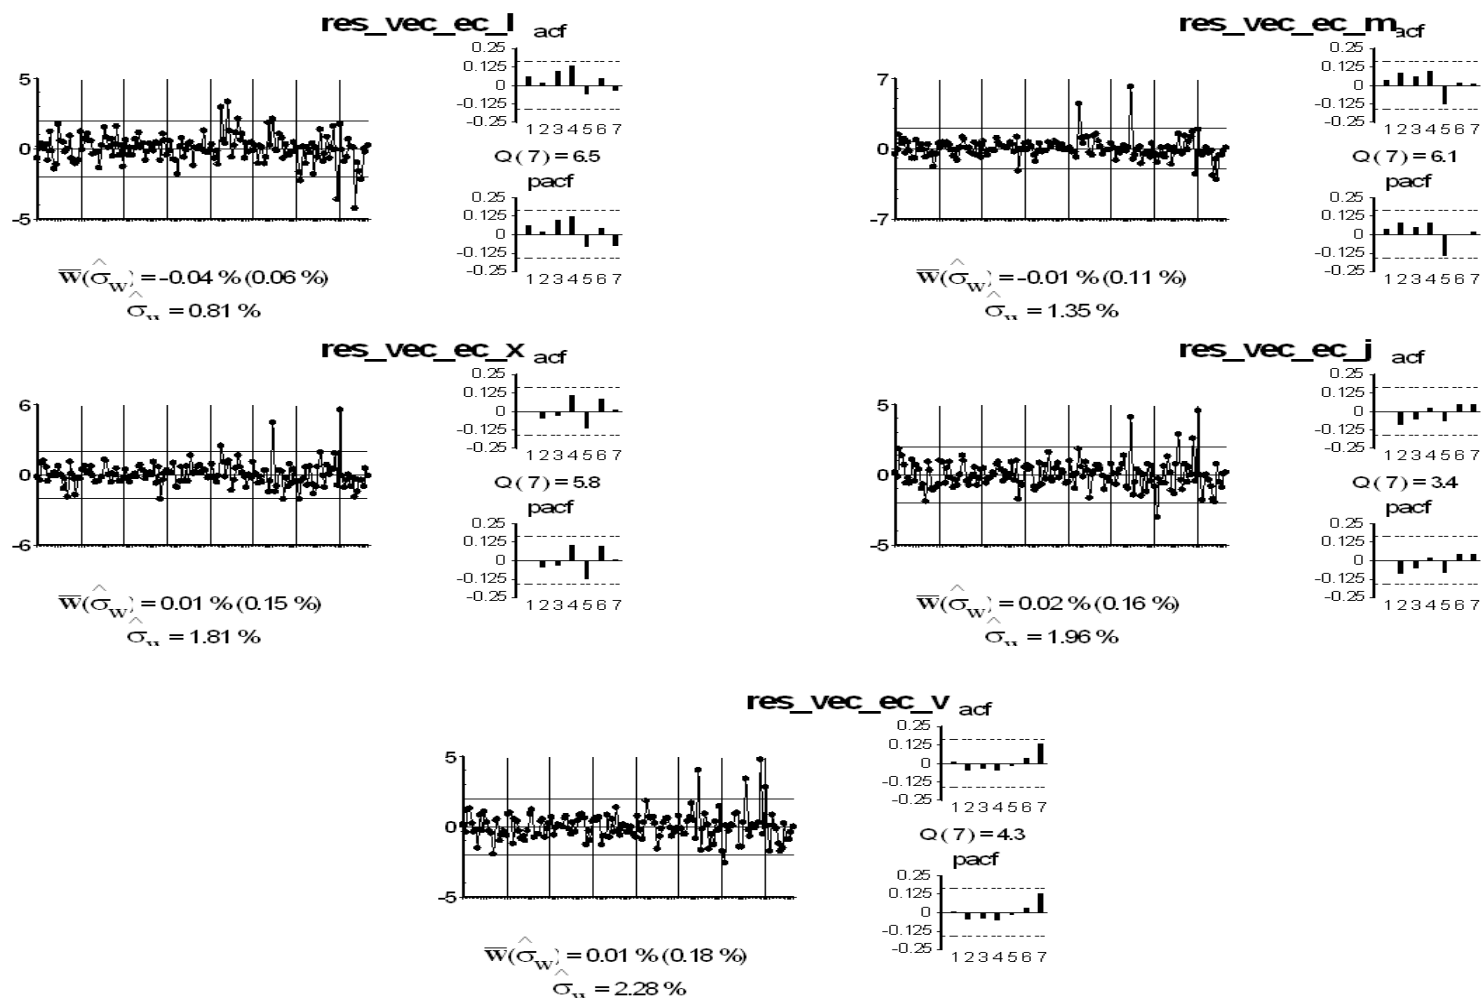


Gráfico 4.32: Iberdrola: Residuos del VEC(1)

Tabla 4.68: Iberdrola: Función de correlación cruzada residual del VEC(1)

Retardos	r_{11}	r_{12}	r_{13}	r_{14}	r_{15}
1	0,064	0,031	0,027	0,020	0,016
2	0,022	0,045	0,005	0,009	0,054
3	0,100	0,198*	0,100	0,081	0,054
4	0,137	0,121	0,116	0,102	0,069
5	-0,065	-0,114	-0,069	-0,069	-0,061
	r_{21}	r_{22}	r_{23}	r_{24}	r_{25}
1	0,097	0,039	0,033	0,020	0,010
2	0,114	0,085	0,002	0,014	0,047
3	-0,056	0,063	0,015	0,038	0,036
4	0,057	0,096	0,153	0,158	0,099
5	-0,039	-0,124	-0,102	-0,053	-0,030
	r_{31}	r_{32}	r_{33}	r_{34}	r_{35}
1	0,059	0,008	-0,003	-0,004	-0,003
2	-0,074	-0,009	-0,045	-0,045	-0,012
3	-0,011	0,086	-0,029	-0,049	-0,042
4	0,036	0,107	0,109	0,098	0,039
5	0,001	-0,126	-0,121	-0,076	-0,024
	r_{41}	r_{42}	r_{43}	r_{44}	r_{45}
1	0,037	0,001	-0,001	-0,003	-0,002
2	-0,104	-0,028	-0,086	-0,090	-0,058
3	-0,019	0,054	-0,032	-0,053	-0,049
4	-0,006	0,030	0,017	0,028	-0,032
5	-0,024	-0,115	-0,101	-0,070	-0,016
	r_{51}	r_{52}	r_{53}	r_{54}	r_{55}
1	0,041	0,017	0,031	0,021	0,013
2	-0,057	0,010	-0,069	-0,075	-0,048
3	-0,074	0,045	0,002	-0,027	-0,042
4	0,003	0,020	-0,010	0,014	-0,050
5	-0,067	-0,134	-0,129	-0,081	-0,017

DT= $\frac{2}{\sqrt{T}}$ = 0,161. En * significativos al 95 %.

Se necesita ortogonalizar el VEC, para representar de forma correcta el modelo periódico. Para conseguir la matriz A_0 con la que se ortogonaliza el modelo, se utiliza la matriz 4.32.

$$A_0 = \begin{pmatrix} 1 & 0 & 0 & 0 & 0 \\ -1,22 & 1 & 0 & 0 & 0 \\ 0,27 & -1,17 & 1 & 0 & 0 \\ 0,01 & 0,15 & -1,08 & 1 & 0 \\ 0,05 & -0,39 & 0,65 & -1,44 & 1 \end{pmatrix} \quad (4.33)$$

Premultiplicando el modelo de la tabla 4.67 por la matriz 4.33 se obtiene el modelo ortogonalizado que representa el modelo periódico, el cual se presenta en la tabla 4.69.

Tabla 4.69: Iberdrola: Modelo VEC(1) ortogonalizado

Variable dependiente	Ecuaciones				
	∇l_t	∇m_t	∇x_t	∇j_t	∇v_t
μ				0,0010	0,0016
$ecm1_{t-1}$	1,15	0,075	1,09	-0,24	-1,14
$ecm2_{t-1}$	1,11	-0,23	0,70	-0,96	0,35
$ecm3_{t-1}$	1,03	-0,021	-0,42	0,016	-0,29
$ecm4_{t-1}$	1,07	-1,31	0,90	-0,071	0,070
∇l_t		1,22	-0,27	-0,0099	-0,055
∇m_t			1,17	-0,15	-0,39
∇x_t				1,08	-0,65
∇j_t					1,44
∇l_{t-1}	-0,11	-0,077	0,21	-0,032	0,074
∇m_{t-1}	0,10	0,063	-0,19	0,029	-0,067
∇x_{t-1}			0,28	0,13	0,056
∇j_{t-1}		0,15	0,23	-0,41	-0,12
∇v_{t-1}	-0,12	-0,25	-0,95	0,40	0,075

4.A.17 Iberia

4.A.17.1 Relaciones de cointegración

Se muestra la existencia de las relaciones de cointegración en la tabla 4.70.

Tabla 4.70: Iberia: Test de cointegración, método de Engle-Granger

Variable dependiente	$p = 0$
$ecm1_t$	-11,36
$ecm2_t$	-11,44
$ecm3_t$	-11,08
$ecm4_t$	-13,05

Valor crítico(95 %):-5,28

(Phillips y Ouliaris (1990)).

El gráfico 4.33 muestra los residuos de estas relaciones de cointegración, y en ellos se observa el carácter estacionario de éstas.

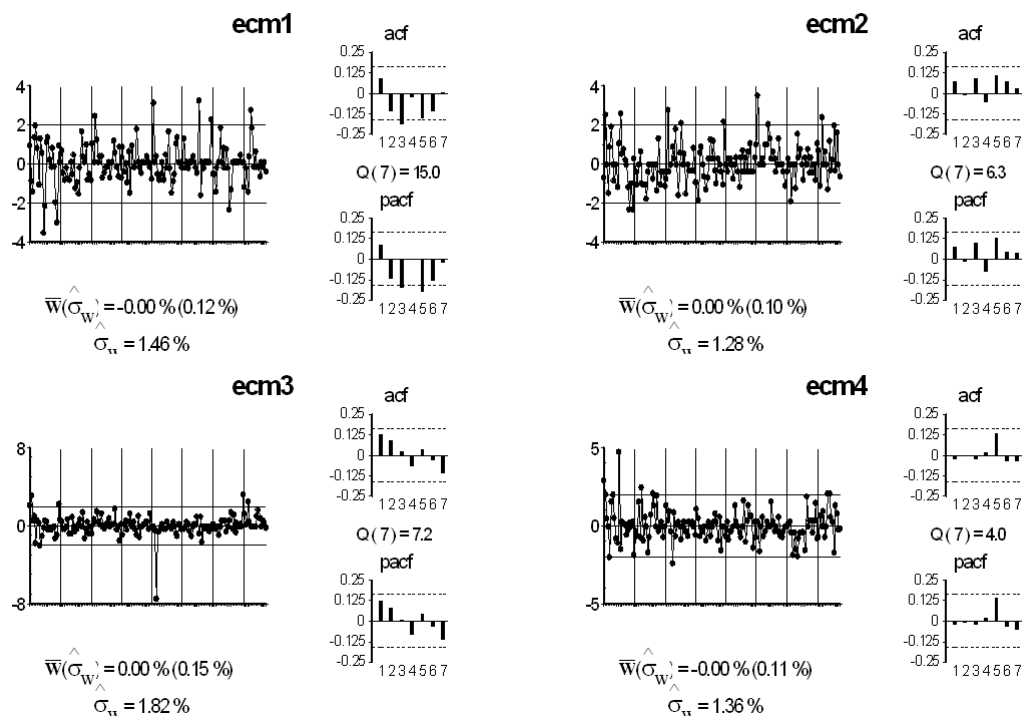


Gráfico 4.33: Iberia: Relaciones de cointegración

4.A.17.2 Estimación modelo VEC

Se estiman todos los parámetros de forma conjunta por mínimos cuadrados generalizados, menos los de las relaciones de cointegración, que se restringen. Los resultados aparecen en la tabla 4.71.

Tabla 4.71: Iberia: Estimación del VEC(2)

Variable dependiente	Ecuaciones ^a				
	∇l_t	∇m_t	∇x_t	∇j_t	∇v_t
μ				0,001 (0,001)	
$ecm1_{t-1}$	1,20 (0,10)	1,11 (0,10)	0,95 (0,09)	1,18 (0,10)	
$ecm2_{t-1}$	0,96 (0,11)	1,20 (0,13)	1,14 (0,17)	0,33 (0,19)	0,52 (0,20)
$ecm3_{t-1}$	0,98 (0,08)	0,94 (0,07)		0,19 (0,09)	0,38 (0,12)
$ecm4_{t-1}$	1,00 (0,09)				0,18 (0,10)
∇l_{t-1}	0,035 (0,067)	0,27 (0,07)	0,22 (0,07)		
∇m_{t-1}				0,30 (0,07)	0,35 (0,09)
∇x_{t-1}	0,11 (0,05)	0,18 (0,06)	0,082 (0,073)		
∇j_{t-1}			-0,14 (0,07)		-0,34 (0,08)
∇v_{t-1}	-0,052 (0,090)	-0,20 (0,07)		-0,21 (0,08)	
∇l_{t-2}			0,098 (0,041)		
∇m_{t-2}			-0,11 (0,05)		
∇x_{t-2}	0,076 (0,039)				
∇j_{t-2}	-0,079 (0,049)				-0,17 (0,06)
∇v_{t-2}	-0,054 (0,076)	-0,30 (0,08)	-0,20 (0,08)	-0,23 (0,06)	

^aLa tabla muestra los coeficientes estimados del modelo VEC donde cada columna representa una ecuación del mismo. Entre paréntesis se presentan las desviaciones típicas.

La matriz de covarianzas se presenta en (4.34).

$$\Sigma_u = \begin{pmatrix} 1,30E-04 & 1,52E-04 & 1,40E-04 & 1,37E-04 & 1,38E-04 \\ 1,52E-04 & 3,56E-04 & 3,97E-04 & 3,90E-04 & 3,81E-04 \\ 1,40E-04 & 3,97E-04 & 7,32E-04 & 7,48E-04 & 6,93E-04 \\ 1,37E-04 & 3,90E-04 & 7,48E-04 & 9,21E-04 & 8,79E-04 \\ 1,38E-04 & 3,81E-04 & 6,93E-04 & 8,79E-04 & 1,02E-03 \end{pmatrix} \quad (4.34)$$

Los residuos del VEC(2) aparecen en el gráfico 4.34. Por otro lado, en la tabla 4.72 se presentan las funciones de correlación cruzadas. En dos casos se aprecian correlaciones significativas en el retardo quinto. Sin embargo, se piensa que el modelo de la tabla 4.71 representa de forma adecuada la relación entre las variables.

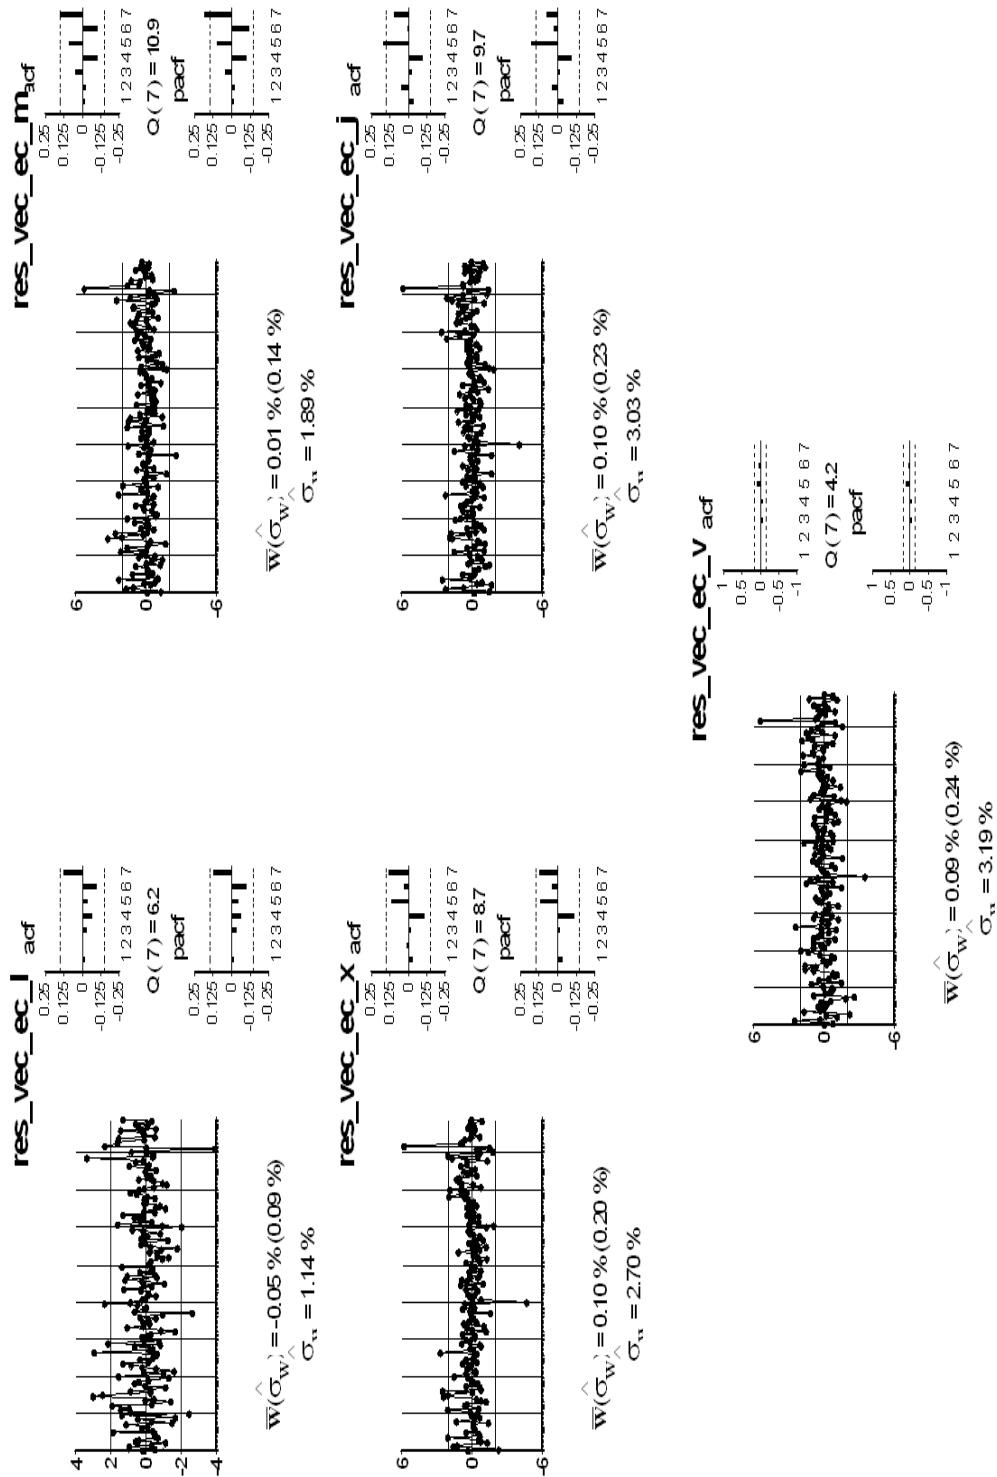


Gráfico 4.34: Iberia: Residuos del VEC(2)

Tabla 4.72: Iberia: Función de correlación cruzada residual del VEC(2)

Retardos	r_{11}	r_{12}	r_{13}	r_{14}	r_{15}
1	-0,015	-0,013	-0,011	-0,007	0,007
2	-0,003	0,006	0,023	-0,003	-0,001
3	-0,032	0,030	0,018	0,004	0,026
4	-0,066	-0,078	-0,076	-0,062	-0,063
5	-0,042	-0,062	-0,040	-0,048	-0,063
	r_{21}	r_{22}	r_{23}	r_{24}	r_{25}
1	-0,035	-0,017	-0,022	-0,021	0,004
2	-0,028	-0,029	0,008	0,003	-0,020
3	0,024	0,048	0,009	-0,001	-0,004
4	-0,106	-0,103	-0,086	-0,036	-0,044
5	0,010	0,094	0,104	0,113	0,054
	r_{31}	r_{32}	r_{33}	r_{34}	r_{35}
1	-0,034	-0,022	-0,030	-0,037	0,003
2	-0,069	-0,045	0,007	0,017	-0,026
3	-0,040	0,003	-0,017	-0,028	-0,040
4	-0,134	-0,120	-0,110	-0,078	-0,054
5	-0,023	0,079	0,121	0,141	0,072
	r_{41}	r_{42}	r_{43}	r_{44}	r_{45}
1	-0,046	-0,025	-0,034	-0,040	0,000
2	-0,072	-0,045	0,022	0,045	-0,003
3	-0,022	0,001	-0,017	-0,023	-0,046
4	-0,139	-0,105	-0,123	-0,094	-0,058
5	-0,055	0,073	0,133	0,171*	0,120
	r_{51}	r_{52}	r_{53}	r_{54}	r_{55}
1	-0,058	-0,034	-0,041	-0,043	0,000
2	-0,051	-0,042	0,024	0,038	-0,004
3	-0,031	-0,018	-0,044	-0,043	-0,075
4	-0,153	-0,090	-0,113	-0,081	-0,059
5	-0,080	0,047	0,144	0,177*	0,105

DT = $\frac{2}{\sqrt{T}} = 0,162$. En * significativos al 95 %.

Se necesita ortogonalizar el VEC, para representar de forma correcta el modelo periódico. Para conseguir la matriz A_0 con la que se ortogonaliza el modelo, se utiliza la matriz 4.34.

$$A_0 = \begin{pmatrix} 1 & 0 & 0 & 0 & 0 \\ -1,15 & 1 & 0 & 0 & 0 \\ 0,56 & -1,32 & 1 & 0 & 0 \\ -0,02 & 0,10 & -1,09 & 1 & 0 \\ -0,05 & -0,07 & 0,23 & -1,11 & 1 \end{pmatrix} \quad (4.35)$$

Premultiplicando el modelo de la tabla 4.71 por la matriz 4.35 se obtiene el modelo ortogonalizado que representa el modelo periódico, el cual se presenta en la tabla 4.73.

Tabla 4.73: Iberia: Modelo VEC(2) ortogonalizado

Variable dependiente	Ecuaciones				
	∇l_t	∇m_t	∇x_t	∇j_t	∇v_t
μ				0,0010	-0,0011
$ecm1_{t-1}$	1,20	-0,28	0,16	0,24	-1,22
$ecm2_{t-1}$	0,96	0,10	0,095	-0,80	0,29
$ecm3_{t-1}$	0,98	-0,19	-0,68	0,27	0,048
$ecm4_{t-1}$	1,00	-1,16	0,56	-0,015	0,14
∇l_t		1,15	-0,56	0,015	0,048
∇m_t			1,32	-0,099	0,071
∇x_t				1,09	-0,23
∇j_t					1,11
∇l_{t-1}	0,035	0,23	-0,11	-0,22	0,032
∇m_{t-1}				0,30	0,018
∇x_{t-1}	0,11	0,049	-0,088	-0,073	0,0014
∇j_{t-1}			-0,14	0,15	-0,38
∇v_{t-1}	-0,052	-0,14	0,23	-0,23	0,25
∇l_{t-2}			0,098	-0,11	0,023
∇m_{t-2}			-0,11	0,12	-0,025
∇x_{t-2}	0,076	-0,088	0,043	-0,0011	-0,0036
∇j_{t-2}	-0,079	0,091	-0,044	0,0012	-0,16
∇v_{t-2}	-0,054	-0,23	0,16	-0,043	0,23

4.A.18 Indra

4.A.18.1 Relaciones de cointegración

Se muestra la existencia de las relaciones de cointegración en la tabla 4.74.

Tabla 4.74: Indra: Test de cointegración, método de Engle-Granger

Variable dependiente	$p = 0$
$ecm1_t$	-12,38
$ecm2_t$	-13,07
$ecm3_t$	-11,08
$ecm4_t$	-11,71

Valor crítico(95 %):-5,28
(Phillips y Ouliaris (1990)).

Los gráficos de los residuos de estas relaciones de cointegración se presentan en el gráfico 4.35 , y en ellos se observa el carácter estacionario de éstas.

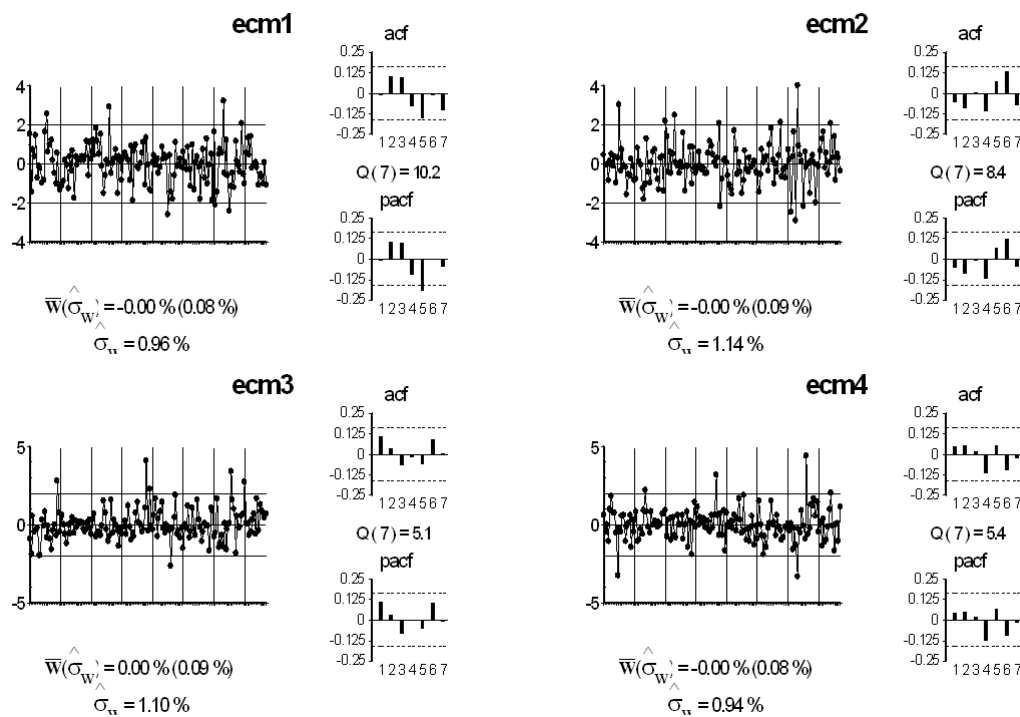


Gráfico 4.35: Indra: Relaciones de cointegración

4.A.18.2 Estimación modelo VEC

Se estiman todos los parámetros de forma conjunta por mínimos cuadrados generalizados, salvo los de las relaciones de cointegración, que se restringen. Los

resultados aparecen en la tabla 4.75.

Tabla 4.75: Indra: Estimación del VEC(0)

Variable dependiente	Ecuaciones ^a				
	∇l_t	∇m_t	∇x_t	∇j_t	∇v_t
μ			0,002 (0,001)	0,004 (0,001)	0,003 (0,002)
$ecm1_{t-1}$	1,15 (0,08)	1,17 (0,11)	0,94 (0,12)	1,02 (0,07)	
$ecm2_{t-1}$	0,95 (0,06)	0,92 (0,08)	1,06 (0,07)		
$ecm3_{t-1}$	1,01 (0,06)	0,99 (0,06)			
$ecm4_{t-1}$	0,99 (0,05)				

^aLa tabla muestra los coeficientes estimados del modelo VEC donde cada columna representa una ecuación del mismo. Entre paréntesis se presentan las desviaciones típicas.

La matriz de covarianzas se presenta en (4.36).

$$\Sigma_u = \begin{pmatrix} 1,17E-04 & 1,36E-04 & 1,31E-04 & 1,35E-04 & 1,29E-04 \\ 1,36E-04 & 2,42E-04 & 2,50E-04 & 2,41E-04 & 2,31E-04 \\ 1,31E-04 & 2,50E-04 & 3,75E-04 & 3,63E-04 & 3,38E-04 \\ 1,35E-04 & 2,41E-04 & 3,63E-04 & 4,81E-04 & 4,89E-04 \\ 1,29E-04 & 2,31E-04 & 3,38E-04 & 4,89E-04 & 5,89E-04 \end{pmatrix} \quad (4.36)$$

En la tabla 4.76 se presentan las funciones de correlación cruzadas. Sólo en dos de ellas se aprecian correlaciones significativas, por lo cual estos resultados sugieren que el modelo de la tabla 4.75 representa de forma adecuada la relación entre las variables. Por su parte, el gráfico 4.36 muestra los residuos del VEC(0).

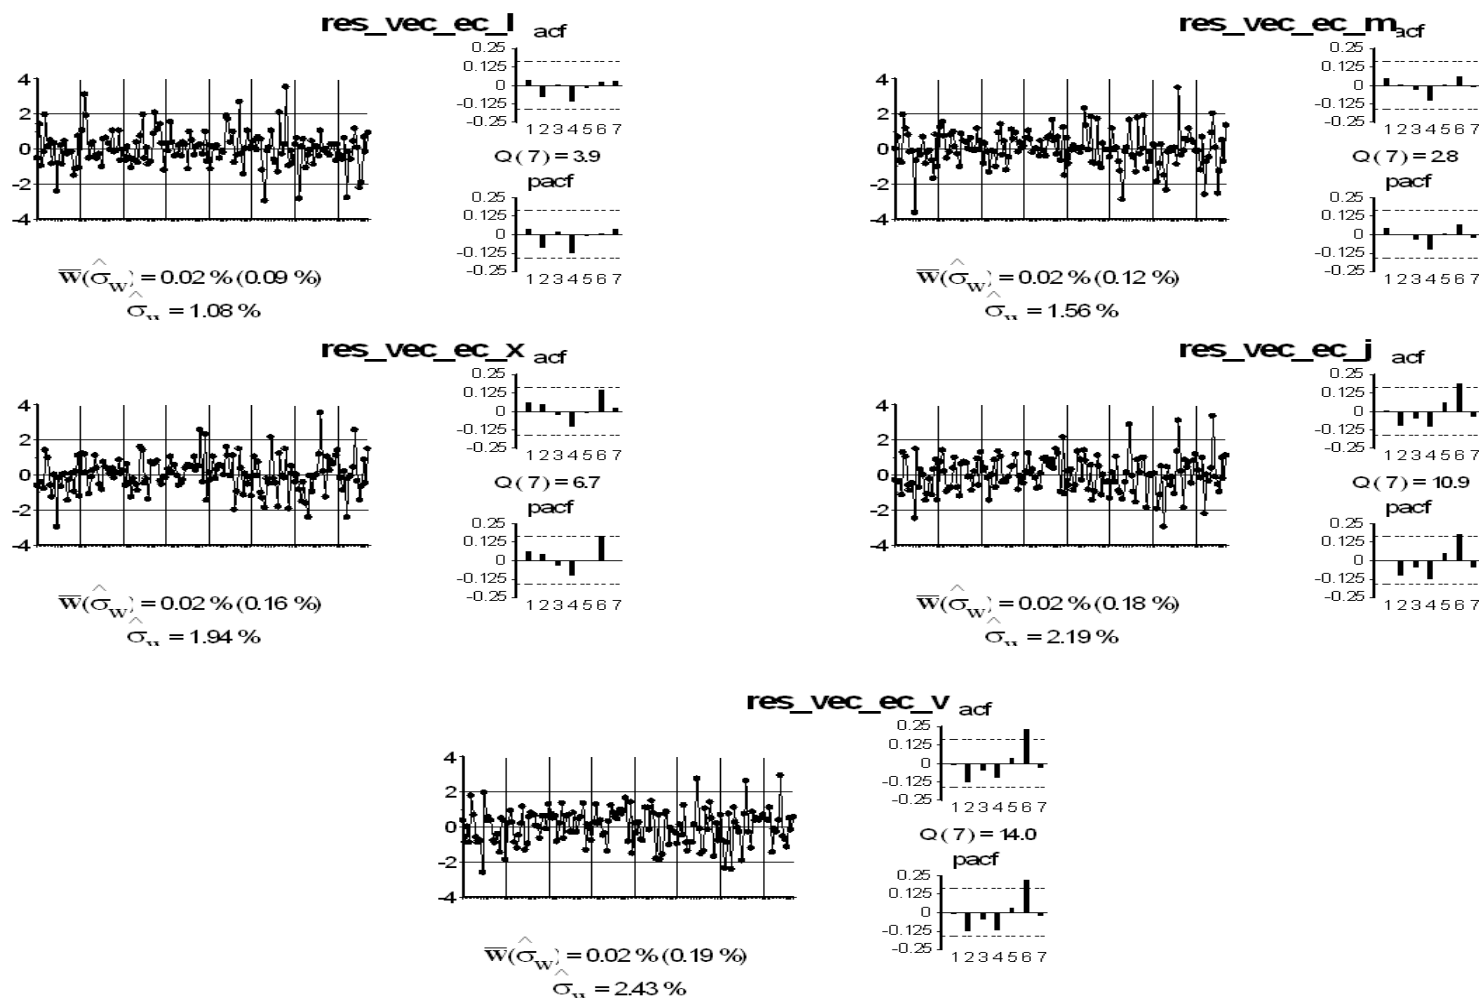


Gráfico 4.36: Indra: Residuos del VEC(0)

Tabla 4.76: Indra: Función de correlación cruzada residual del VEC(0)

Retardos	r_{11}	r_{12}	r_{13}	r_{14}	r_{15}
1	0,041	0,057	0,083	0,066	0,068
2	-0,085	-0,048	-0,003	-0,089	-0,127
3	0,006	-0,008	-0,023	-0,017	0,010
4	-0,113	-0,105	-0,084	-0,036	-0,033
5	-0,019	-0,084	-0,086	-0,078	-0,096
	r_{21}	r_{22}	r_{23}	r_{24}	r_{25}
1	0,027	0,050	0,096	0,070	0,073
2	-0,036	0,005	0,052	-0,054	-0,086
3	-0,044	-0,030	-0,001	0,035	0,039
4	-0,060	-0,102	-0,113	-0,062	-0,029
5	0,039	0,003	-0,033	-0,006	-0,030
	r_{31}	r_{32}	r_{33}	r_{34}	r_{35}
1	-0,043	-0,011	0,065	0,042	0,050
2	-0,057	0,011	0,050	-0,075	-0,109
3	-0,098	-0,026	-0,025	0,027	0,020
4	-0,087	-0,094	-0,102	-0,051	-0,010
5	0,064	0,041	-0,009	0,020	0,011
	r_{41}	r_{42}	r_{43}	r_{44}	r_{45}
1	-0,073	-0,053	0,022	0,003	0,018
2	-0,115	-0,032	0,034	-0,101	-0,137
3	-0,101	-0,079	-0,097	-0,046	-0,040
4	-0,186*	-0,142	-0,128	-0,108	-0,071
5	0,061	0,061	0,019	0,061	0,042
	r_{51}	r_{52}	r_{53}	r_{54}	r_{55}
1	-0,082	-0,077	-0,019	-0,028	-0,009
2	-0,131	-0,076	-0,006	-0,111	-0,125
3	-0,134	-0,105	-0,131	-0,068	-0,044
4	-0,183*	-0,117	-0,111	-0,119	-0,097
5	0,074	0,080	0,051	0,085	0,040

DT= $\frac{2}{\sqrt{T}} = 0,161$. En * significativos al 95 %

Se necesita ortogonalizar el VEC, para representar de forma correcta el modelo periódico. Para conseguir la matriz A_0 con la que se ortogonaliza el modelo, se utiliza la matriz 4.36.

$$A_0 = \begin{pmatrix} 1 & 0 & 0 & 0 & 0 \\ -1,16 & 1 & 0 & 0 & 0 \\ 0,21 & -1,15 & 1 & 0 & 0 \\ -0,22 & 0,15 & -0,99 & 1 & 0 \\ 0,12 & -0,18 & 0,39 & -1,26 & 1 \end{pmatrix} \quad (4.37)$$

Premultiplicando el modelo de la tabla 4.75 por la matriz 4.37 se obtiene el modelo ortogonalizado que representa el modelo periódico, el cual se presenta en la tabla 4.77.

Tabla 4.77: Indra: Modelo VEC(0) ortogonalizado

Variable dependiente	Ecuaciones				
	∇l_t	∇m_t	∇x_t	∇j_t	∇v_t
μ			0,0020	0,0020	-0,0012
$ecm1_{t-1}$	1,15	-0,17	-0,16	0,017	-0,99,
$ecm2_{t-1}$	0,96	-0,19	0,20	-1,12	0,36
$ecm3_{t-1}$	1,01	-0,19	-0,92	-0,067	-0,059
$ecm4_{t-1}$	0,99	-1,15	0,21	-0,21	0,11
∇l_t		1,17	-0,21	0,22	-0,11
∇m_t			1,15	-0,15	0,18
∇x_t				0,99	-0,39
∇j_t					1,26

4.A.19 Inditex

4.A.19.1 Relaciones de cointegración

Se muestra la existencia de las relaciones de cointegración en la tabla 4.78.

Tabla 4.78: Inditex: Test de cointegración, método de Engle-Granger

Variable dependiente	$p = 0$
$ecm1_t$	-11,88
$ecm2_t$	-13,35
$ecm3_t$	-13,22
$ecm4_t$	-12,85

Valor crítico(95 %):-5,28

(Phillips y Ouliaris (1990)).

Los gráficos de los residuos de estas relaciones de cointegración se presentan en el gráfico 4.37 , y en él se observa el carácter estacionario de éstas.

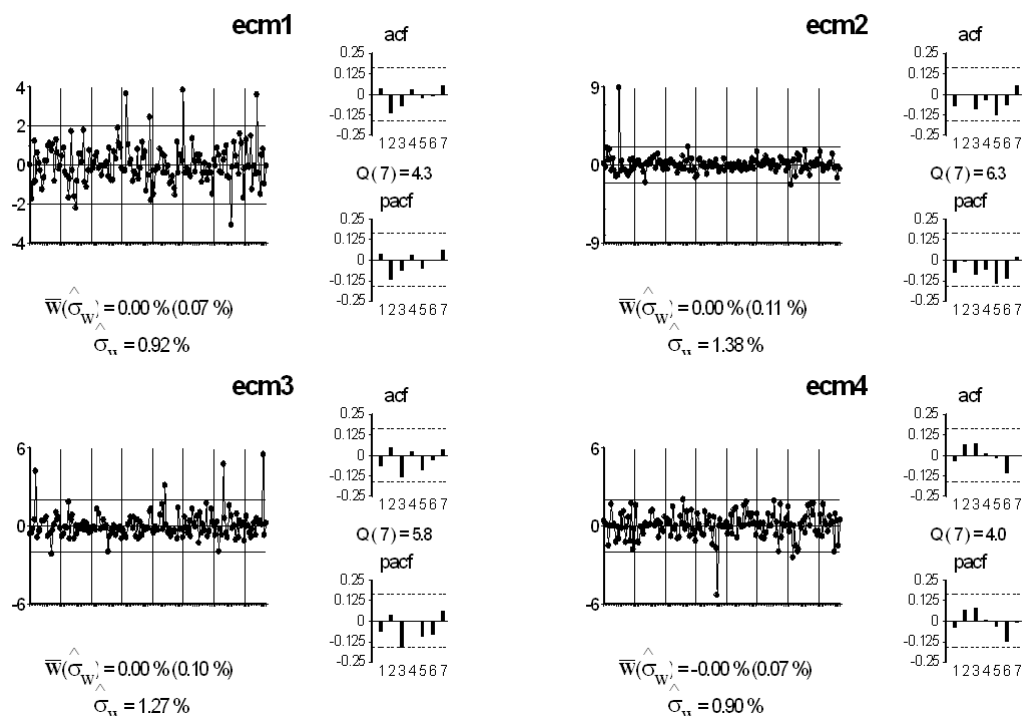


Gráfico 4.37: Inditex: Relaciones de cointegración

4.A.19.2 Estimación modelo VEC

Se estiman todos los parámetros de forma conjunta por mínimos cuadrados generalizados, menos los de las relaciones de cointegración, que se restringen. Los resultados aparecen en la tabla 4.79.

Tabla 4.79: Inditex: Estimación del VEC(0)

Variable dependiente	Ecuaciones ^a				
	∇l_t	∇m_t	∇x_t	∇j_t	∇v_t
μ				0,002 (0,001)	0,003 (0,001)
$ecm1_{t-1}$	1,08 (0,09)	1,18 (0,09)	1,21 (0,08)	1,15 (0,07)	
$ecm2_{t-1}$	1,01 (0,08)	0,82 (0,07)	0,92 (0,06)		
$ecm3_{t-1}$	1,17 (0,10)	1,06 (0,07)			
$ecm4_{t-1}$	1,05 (0,06)				

^aLa tabla muestra los coeficientes estimados del modelo VEC donde cada columna representa una ecuación del mismo. Entre paréntesis se presentan las desviaciones típicas.

La matriz de covarianzas se presenta en (4.38).

$$\Sigma_u = \begin{pmatrix} 1,61E-04 & 1,42E-04 & 1,32E-04 & 1,40E-04 & 1,40E-04 \\ 1,42E-04 & 2,39E-04 & 2,33E-04 & 2,48E-04 & 2,51E-04 \\ 1,32E-04 & 2,33E-04 & 3,02E-04 & 3,36E-04 & 3,25E-04 \\ 1,40E-04 & 2,48E-04 & 3,36E-04 & 4,99E-04 & 4,82E-04 \\ 1,40E-04 & 2,51E-04 & 3,25E-04 & 4,82E-04 & 5,74E-04 \end{pmatrix} \quad (4.38)$$

Los residuos del VEC(0) aparecen en el gráfico 4.38. Por otro lado, en la tabla 4.80 se presentan las funciones de correlación cruzadas. Una de ellas es significativa, se considera que no es necesario incrementar el orden del VEC(0) y que el modelo de la tabla 4.79 es adecuado para representar la relación entre las variables.

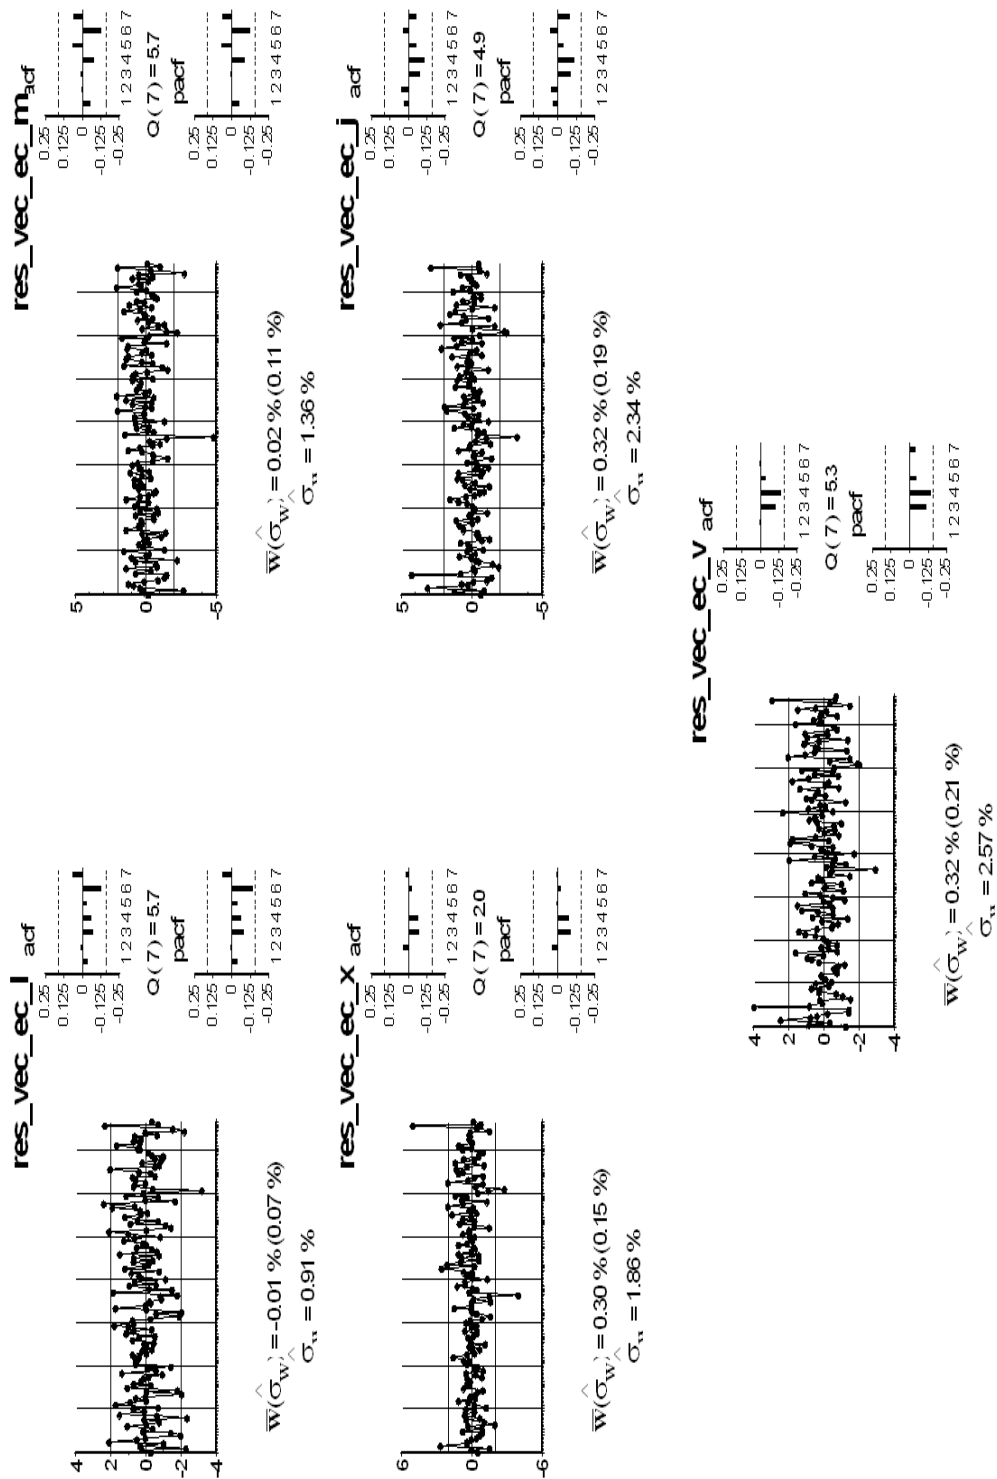


Gráfico 4.38: Inditex: Residuos del VEC(0)

Tabla 4.80: Inditex: Función de correlación cruzada residual del VEC(0)

Retardos	r_{11}	r_{12}	r_{13}	r_{14}	r_{15}
1	-0,039	-0,034	0,016	0,043	0,025
2	0,014	0,023	0,063	0,075	0,059
3	-0,078	0,024	0,004	0,073	0,074
4	-0,064	-0,147	-0,157	-0,078	-0,034
5	-0,036	0,020	0,027	0,002	0,026
	r_{21}	r_{22}	r_{23}	r_{24}	r_{25}
1	-0,057	-0,051	0,011	0,043	0,018
2	-0,006	0,005	0,058	0,070	0,047
3	-0,112	0,010	0,017	0,079	0,072
4	-0,016	-0,086	-0,100	-0,077	-0,066
5	0,072	0,071	0,068	0,030	0,025
	r_{31}	r_{32}	r_{33}	r_{34}	r_{35}
1	-0,071	-0,069	0,000	0,017	-0,014
2	-0,006	-0,021	0,040	0,045	0,011
3	-0,105	-0,019	-0,075	-0,027	-0,047
4	-0,025	-0,076	-0,068	-0,109	-0,044
5	0,078	0,025	-0,004	-0,026	-0,023
	r_{41}	r_{42}	r_{43}	r_{44}	r_{45}
1	-0,104	-0,078	0,015	0,036	0,001
2	-0,041	-0,052	0,038	0,046	0,002
3	-0,056	-0,015	-0,096	-0,082	-0,107
4	0,055	0,001	-0,060	-0,115	-0,084
5	0,011	0,052	0,009	-0,053	-0,034
	r_{51}	r_{52}	r_{53}	r_{54}	r_{55}
1	-0,086	-0,071	0,005	0,037	-0,001
2	-0,047	-0,059	0,030	0,049	0,006
3	-0,021	0,017	-0,085	-0,065	-0,104
4	0,023	-0,043	-0,140	-0,184*	-0,143
5	-0,004	0,072	-0,005	-0,059	-0,043

DT = $\frac{2}{\sqrt{T}} = 0,161$. En * significativos al 95 %

Se necesita ortogonalizar el VEC, para representar de forma correcta el modelo periódico. Para conseguir la matriz A_0 con la que se ortogonaliza el modelo, se utiliza la matriz 4.38.

$$A_0 = \begin{pmatrix} 1 & 0 & 0 & 0 & 0 \\ -0,88 & 1 & 0 & 0 & 0 \\ 0,08 & -1,02 & 1 & 0 & 0 \\ -0,02 & 0,21 & -1,27 & 1 & 0 \\ 0,06 & -0,22 & 0,15 & -0,97 & 1 \end{pmatrix} \quad (4.39)$$

Premultiplicando el modelo de la tabla 4.79 por la matriz 4.39 se obtiene el modelo ortogonalizado que representa el modelo periódico, el cual se presenta en la tabla 4.81.

Tabla 4.81: Inditex: Modelo VEC(0) ortogonalizado

Variable dependiente	Ecuaciones				
	∇l_t	∇m_t	∇x_t	∇j_t	∇v_t
μ				0,0020	0,0011
$ecm1_{t-1}$	1,08	0,23	0,097	-0,16	-1,14
$ecm2_{t-1}$	1,01	-0,074	0,17	-1,01	0,014
$ecm3_{t-1}$	1,17	0,027	-0,99	0,20	-0,17
$ecm4_{t-1}$	1,05	-0,92	0,083	-0,020	0,058
∇l_t		0,88	-0,080	0,019	-0,055
∇m_t			1,02	-0,21	0,22
∇x_t				1,27	-0,15
∇j_t					0,97

4.A.20 Metrovacesa

4.A.20.1 Relaciones de cointegración

Se muestra la existencia de las relaciones de cointegración en la tabla 4.82.

Tabla 4.82: Metrovacesa: Test de cointegración, método de Engle-Granger

Variable dependiente	$p = 0$
$ecm1_t$	-14,07
$ecm2_t$	-17,89
$ecm3_t$	-14,06
$ecm4_t$	-13,29

Valor crítico(95 %):-5,28

(Phillips y Ouliaris (1990)).

Los gráficos de los residuos de estas relaciones de cointegración se presentan en el gráfico 4.39 , y en ellos se observa el carácter estacionario de éstas.

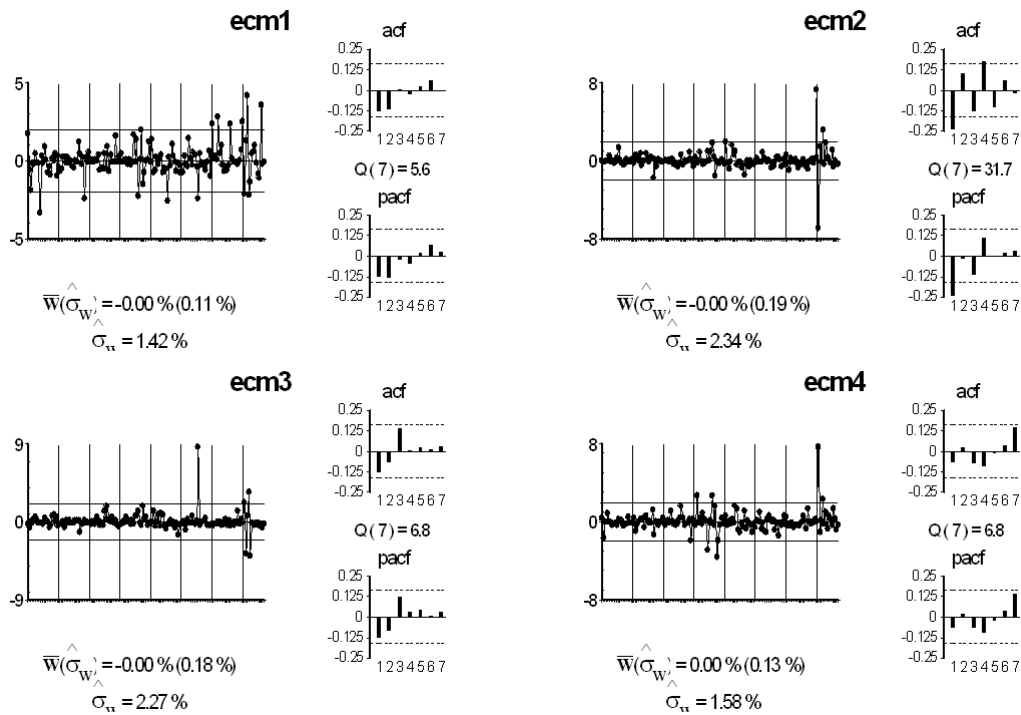


Gráfico 4.39: Metrovacesa: Residuos de las relaciones de cointegración

4.A.20.2 Estimación modelo VEC

Se estiman todos los parámetros de forma conjunta por mínimos cuadrados generalizados, salvo los de las relaciones de cointegración, que se restringen. Los resultados aparecen en la tabla 4.83.

Tabla 4.83: Metrovacesa: Estimación del VEC(2)

Variable dependiente	Ecuaciones ^a				
	∇l_t	∇m_t	∇x_t	∇j_t	∇v_t
$ecm1_{t-1}$	0,90 (0,15)	0,88 (0,19)	0,94 (0,25)	1,20 (0,13)	
$ecm2_{t-1}$	1,17 (0,11)	1,50 (0,14)	1,31 (0,16)	-0,30 (0,21)	-0,52 (0,23)
$ecm3_{t-1}$	0,74 (0,11)	0,64 (0,13)	-0,32 (0,19)	-0,37 (0,20)	-0,48 (0,23)
$ecm4_{t-1}$	1,04 (0,09)				
∇l_{t-1}	-0,15 (0,08)	-0,22 (0,10)	-0,093 (0,100)		
∇x_{t-1}	0,37 (0,08)	0,38 (0,07)		-0,22 (0,11)	-0,27 (0,13)
∇j_{t-1}	-0,42 (0,12)	-0,42 (0,13)	-0,36 (0,15)		
∇v_{t-1}	0,23 (0,12)	0,27 (0,14)	0,50 (0,19)	0,38 (0,15)	0,50 (0,16)
∇l_{t-2}	-0,090 (0,026)	-0,19 (0,05)			
∇m_{t-2}		0,12 (0,05)			
∇x_{t-2}	0,15 (0,04)		-0,20 (0,05)	-0,32 (0,08)	-0,23 (0,09)
∇j_{t-2}	-0,18 (0,07)			0,13 (0,06)	
∇v_{t-2}	0,21 (0,08)	0,24 (0,09)	0,40 (0,11)	0,31 (0,12)	0,39 (0,12)

^aLa tabla muestra los coeficientes estimados del modelo VEC donde cada columna representa una ecuación del mismo. Entre paréntesis se presentan las desviaciones típicas.

La matriz de covarianzas se presenta en (4.40).

$$\Sigma_u = \begin{pmatrix} 1,69E-04 & 2,17E-04 & 2,65E-04 & 2,18E-04 & 1,98E-04 \\ 2,17E-04 & 4,29E-04 & 5,36E-04 & 4,53E-04 & 4,39E-04 \\ 2,65E-04 & 5,36E-04 & 1,08E-03 & 1,01E-03 & 1,01E-03 \\ 2,18E-04 & 4,53E-04 & 1,01E-03 & 1,42E-03 & 1,44E-03 \\ 1,98E-04 & 4,39E-04 & 9,45E-03 & 1,44E-03 & 1,63E-03 \end{pmatrix} \quad (4.40)$$

El gráfico 4.40 muestra los residuos del VEC(2). Por otro lado, en la tabla 4.84 se presentan las funciones de correlación cruzadas. Ninguna de las correlaciones de la tabla es significativa, por lo que se considera que el modelo de la tabla 4.83 representa de forma adecuada la correlación dinámica entre las variables.

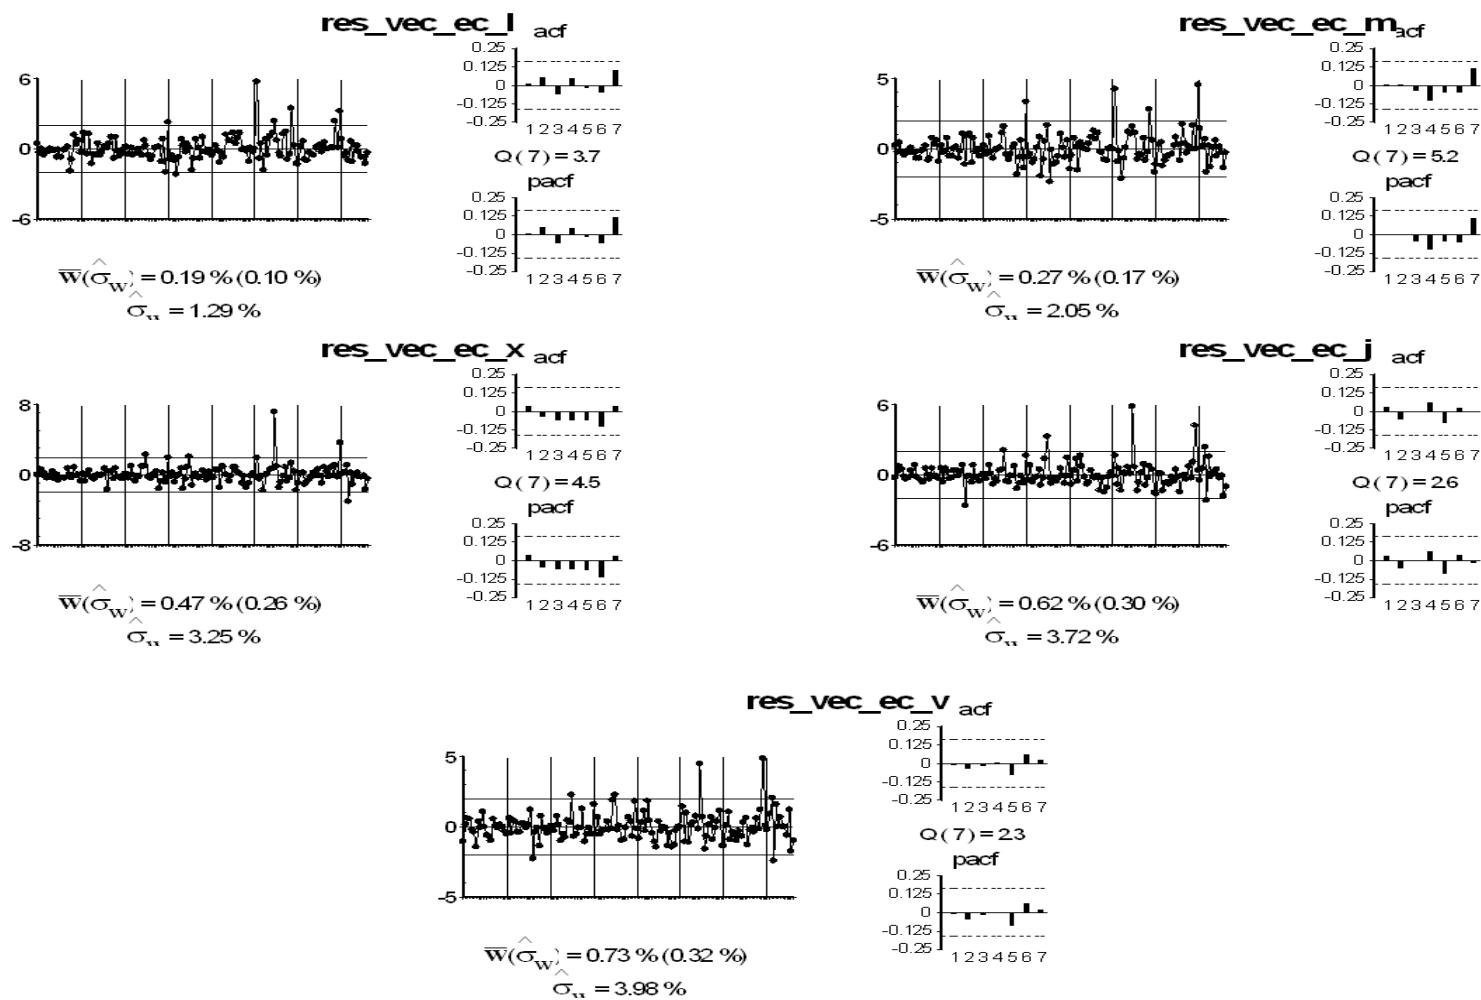


Gráfico 4.40: Metrovacesa: Residuos del VEC(2)

Tabla 4.84: Metrovacesa: Función de correlación cruzada residual del VEC(2)

Retardos	r_{11}	r_{12}	r_{13}	r_{14}	r_{15}
1	0,010	0,014	0,004	-0,008	-0,020
2	0,054	-0,011	-0,041	-0,044	-0,044
3	-0,060	-0,064	-0,028	-0,020	-0,017
4	0,045	-0,049	0,026	0,026	-0,017
5	-0,021	-0,021	0,027	-0,017	-0,040
	r_{21}	r_{22}	r_{23}	r_{24}	r_{25}
1	0,002	0,007	0,016	0,008	-0,011
2	0,068	0,000	-0,020	-0,032	-0,030
3	0,017	-0,043	-0,030	-0,021	-0,009
4	-0,017	-0,107	-0,092	-0,058	-0,078
5	-0,029	-0,049	-0,014	-0,062	-0,073
	r_{31}	r_{32}	r_{33}	r_{34}	r_{35}
1	0,028	0,021	0,042	0,028	-0,003
2	0,055	0,006	-0,042	-0,055	-0,044
3	-0,065	-0,084	-0,063	-0,045	-0,029
4	0,012	-0,115	-0,065	0,017	0,014
5	-0,106	-0,127	-0,062	-0,134	-0,129
	r_{41}	r_{42}	r_{43}	r_{44}	r_{45}
1	0,033	0,023	0,041	0,033	-0,010
2	0,048	0,009	-0,050	-0,055	-0,053
3	-0,051	-0,060	-0,016	-0,004	0,006
4	0,034	-0,076	-0,041	0,062	0,064
5	-0,063	-0,045	-0,001	-0,087	-0,087
	r_{51}	r_{52}	r_{53}	r_{54}	r_{55}
1	0,022	0,015	0,036	0,032	-0,010
2	0,057	0,019	-0,042	-0,040	-0,043
3	-0,048	-0,059	-0,031	-0,019	-0,016
4	0,004	-0,110	-0,077	0,007	0,007
5	-0,021	-0,019	0,020	-0,086	-0,087

DT= $\frac{2}{\sqrt{T}}$ = 0,162. En * significativos al 95 %.

Se necesita ortogonalizar el VEC, para representar de forma correcta el modelo periódico. Para conseguir la matriz A_0 con la que se ortogonaliza el modelo, se utiliza la matriz 4.40.

$$A_0 = \begin{pmatrix} 1 & 0 & 0 & 0 & 0 \\ -1,28 & 1 & 0 & 0 & 0 \\ 0,11 & -1,30 & 1 & 0 & 0 \\ 0,08 & 0,26 & -1,08 & 1 & 0 \\ 0,21 & -0,27 & 0,31 & -1,18 & 1 \end{pmatrix} \quad (4.41)$$

Premultiplicando el modelo de la tabla 4.83 por la matriz 4.41 se obtiene el modelo ortogonalizado que representa el modelo periódico, el cual se presenta en la tabla 4.85.

Tabla 4.85: Metrovacesa: Modelo VEC(2) ortogonalizado

Variable dependiente	Ecuaciones				
	∇l_t	∇m_t	∇x_t	∇j_t	∇v_t
$ecm1_{t-1}$	0,90	-0,27	-0,11	0,47	-1,17
$ecm2_{t-1}$	1,17	-0,0099	-0,51	-1,25	0,074
$ecm3_{t-1}$	0,74	-0,31	-1,07	-0,15	0,24
$ecm4_{t-1}$	1,04	-1,33	0,11	0,083	0,22
∇l_t		1,28	-0,11	-0,47	-0,21
∇m_t			1,30	-0,26	0,27
∇x_t				1,08	-0,31
∇j_t					1,18
∇l_{t-1}	-0,15	-0,024	0,17	0,033	-0,0009
∇x_{t-1}	0,37	-0,090	-0,46	-0,091	-0,040
∇j_{t-1}	-0,42	0,12	0,14	0,25	-0,086
∇v_{t-1}	0,23	-0,018	0,17	-0,072	0,19
∇l_{t-2}	-0,090	-0,075	0,23	-0,056	0,033
∇m_{t-2}		0,12	-0,16	0,031	-0,033
∇x_{t-2}	0,15	-0,19	-0,18	-0,095	0,12
∇j_{t-2}	-0,18	0,23	-0,020	0,12	-0,19
∇v_{t-2}	0,21	-0,029	0,11	-0,21	0,33

4.A.21 Banco Popular

4.A.21.1 Relaciones de cointegración

En la tabla 4.86 se muestra la existencia de las relaciones de cointegración.

Tabla 4.86: Banco Popular: Test de cointegración, método de Engle-Granger

Variable dependiente	$p = 0$
$ecm1_t$	-13,71
$ecm2_t$	-11,80
$ecm3_t$	-11,00
$ecm4_t$	-13,38

Valor crítico(95 %):-5,28
(Phillips y Ouliaris (1990)).

El gráfico 4.41 muestra los residuos de estas relaciones de cointegración, y en ellos se observa el carácter estacionario de éstas.

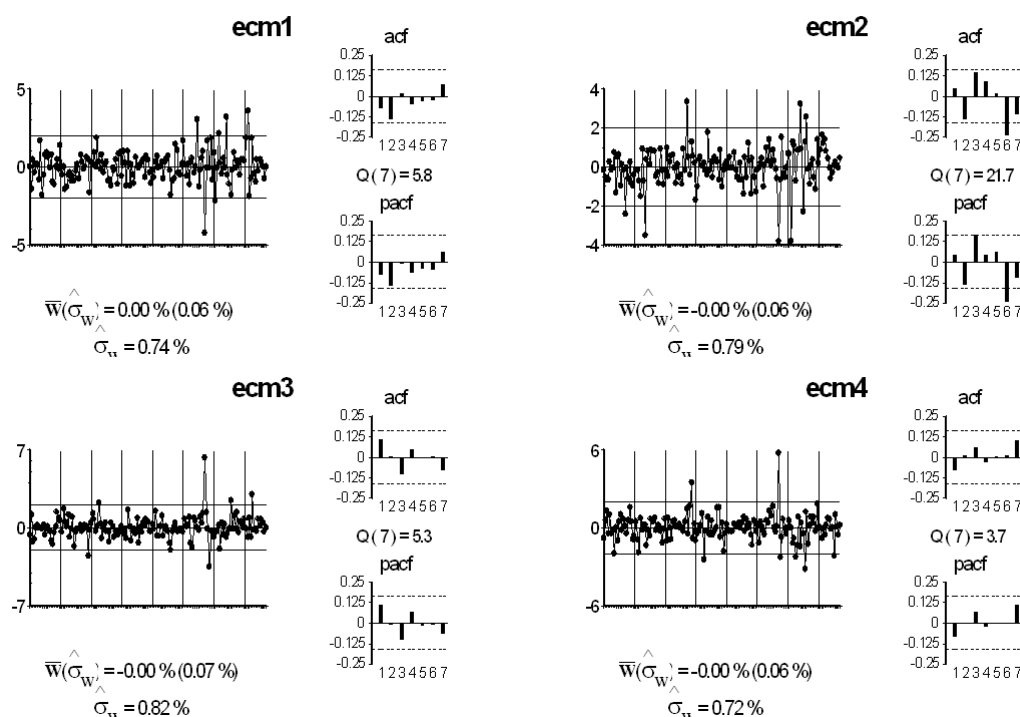


Gráfico 4.41: Banco Popular: Relaciones de cointegración

4.A.21.2 Estimación modelo VEC

Se estiman todos los parámetros de forma conjunta por mínimos cuadrados generalizados, menos los de las relaciones de cointegración, que se restringen. Los

resultados aparecen en la tabla 4.87.

Tabla 4.87: Banco Popular: Estimación del VEC(1)

Variable dependiente	Ecuaciones ^a				
	∇l_t	∇m_t	∇x_t	∇j_t	∇v_t
$ecm1_{t-1}$	1,13 (0,07)	1,08 (0,10)	0,95 (0,13)	0,92 (0,10)	
$ecm2_{t-1}$	1,08 (0,06)	1,09 (0,09)	0,91 (0,10)		0,34 (0,10)
$ecm3_{t-1}$	0,96 (0,06)	0,76 (0,11)	-0,29 (0,13)	-0,23 (0,10)	
$ecm4_{t-1}$	1,13 (0,06)				0,47 (0,13)
∇l_{t-1}					0,18 (0,07)
∇m_{t-1}				-0,12 (0,04)	-0,29 (0,09)
∇v_{t-1}		0,12 (0,06)	0,23 (0,08)	0,22 (0,07)	

^aLa tabla muestra los coeficientes estimados del modelo VEC donde cada columna representa una ecuación del mismo. Entre paréntesis se presentan las desviaciones típicas.

La matriz de covarianzas se presenta en (4.42).

$$\Sigma_u = \begin{pmatrix} 4,83E-05 & 5,45E-05 & 6,30E-05 & 6,35E-05 & 5,47E-05 \\ 5,45E-05 & 1,10E-04 & 1,31E-04 & 1,25E-04 & 1,07E-04 \\ 6,30E-05 & 1,31E-04 & 2,18E-04 & 2,08E-04 & 1,82E-04 \\ 6,35E-05 & 1,25E-04 & 2,08E-04 & 2,54E-04 & 2,40E-04 \\ 5,47E-05 & 1,07E-04 & 1,82E-04 & 2,40E-04 & 2,74E-04 \end{pmatrix} \quad (4.42)$$

En la tabla 4.88 se presentan las funciones de correlación cruzadas. Aunque aparecen cinco correlaciones significativas en el tercer retardo, se considera que el modelo de la tabla 4.87 representa de forma adecuada la relación entre las variables. Por otro lado, los residuos del VEC(1) aparecen en el gráfico 4.42.

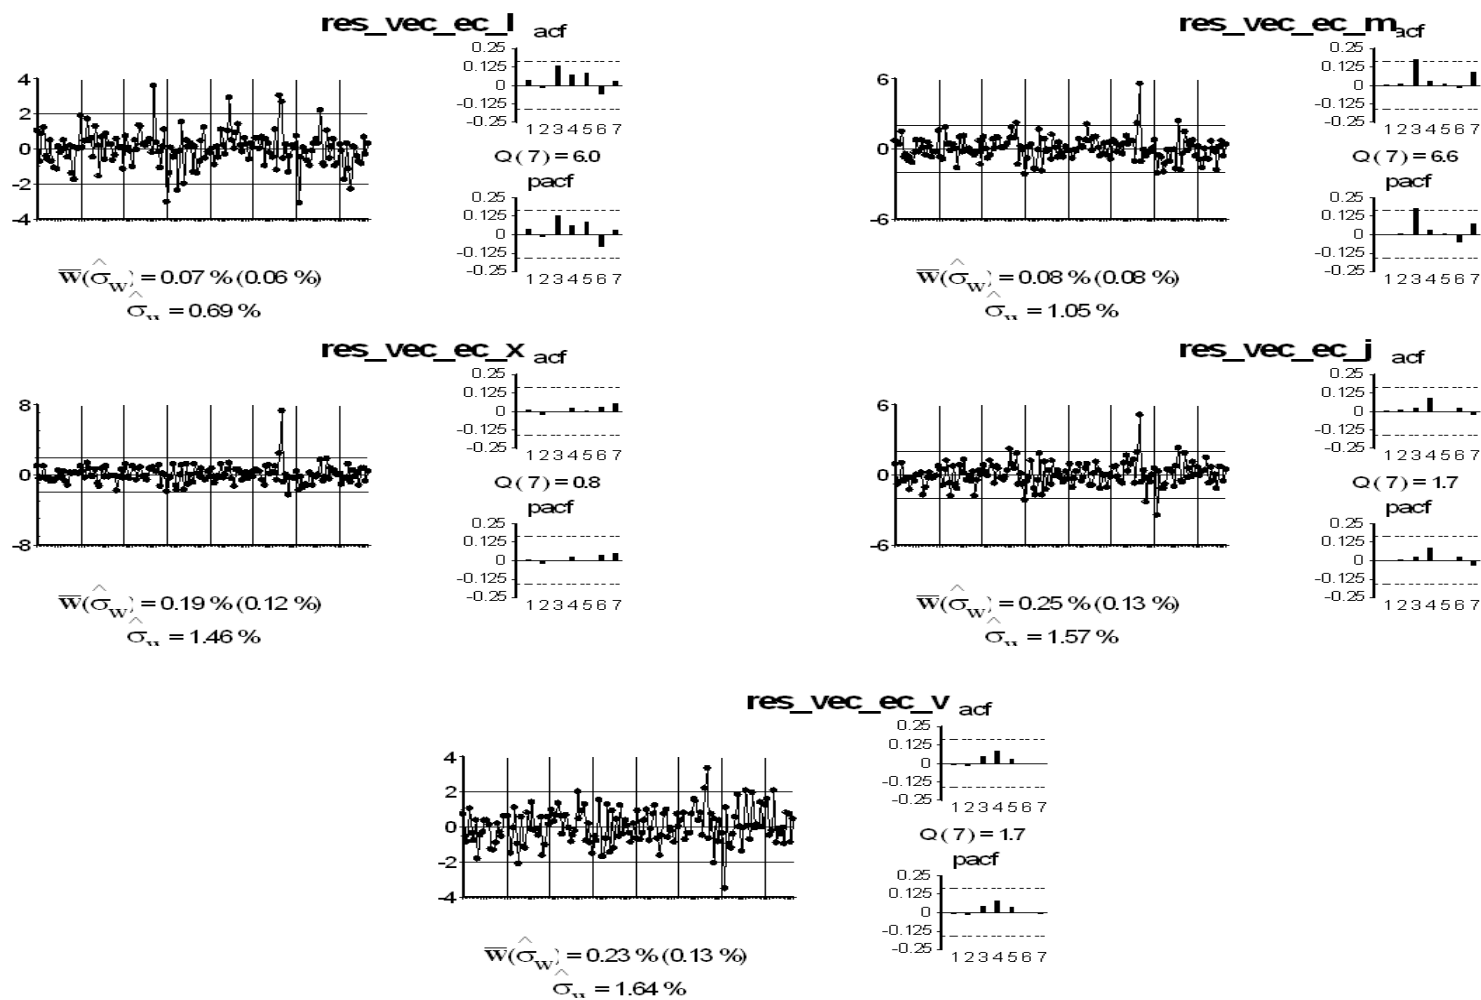


Gráfico 4.42: Banco Popular: Residuos del VEC(1)

Tabla 4.88: Banco Popular: Función de correlación cruzada residual del VEC(1)

Retardos	r_{11}	r_{12}	r_{13}	r_{14}	r_{15}
1	0,042	0,018	0,022	0,021	0,013
2	-0,020	0,008	-0,005	-0,040	-0,020
3	0,133	0,169*	0,129	0,166*	0,142
4	0,075	0,015	0,052	0,031	0,047
5	0,084	0,014	0,011	0,011	-0,008
	r_{21}	r_{22}	r_{23}	r_{24}	r_{25}
1	0,052	0,007	0,020	0,020	0,013
2	-0,008	0,014	-0,023	-0,044	-0,046
3	0,177*	0,178*	0,143	0,191*	0,149
4	0,105	0,031	0,058	0,070	0,093
5	0,046	0,014	0,004	0,004	-0,004
	r_{31}	r_{32}	r_{33}	r_{34}	r_{35}
1	0,013	-0,020	0,008	0,003	-0,006
2	-0,027	-0,020	-0,023	-0,005	-0,022
3	0,059	0,028	0,000	0,070	0,080
4	0,015	-0,019	0,023	0,060	0,074
5	0,015	0,009	0,001	0,001	0,028
	r_{41}	r_{42}	r_{43}	r_{44}	r_{45}
1	-0,046	-0,035	0,001	0,001	-0,003
2	-0,015	-0,013	-0,011	0,009	-0,012
3	0,019	-0,058	-0,083	0,027	0,065
4	0,041	0,006	0,049	0,091	0,100
5	0,013	0,006	-0,007	-0,001	0,023
	r_{51}	r_{52}	r_{53}	r_{54}	r_{55}
1	-0,057	-0,029	0,009	0,004	-0,010
2	-0,049	-0,030	0,008	0,029	-0,020
3	-0,035	-0,075	-0,112	-0,002	0,044
4	0,100	0,045	0,073	0,090	0,082
5	0,003	-0,007	0,000	0,017	0,035

DT = $\frac{2}{\sqrt{T}} = 0,161$. En * significativos al 95 %

Se necesita ortogonalizar el VEC, para representar de forma correcta el modelo periódico. Para conseguir la matriz A_0 con la que se ortogonaliza el modelo, se utiliza la matriz 4.42.

$$A_0 = \begin{pmatrix} 1 & 0 & 0 & 0 & 0 \\ -1,11 & 1 & 0 & 0 & 0 \\ 0,07 & -1,23 & 1 & 0 & 0 \\ -0,14 & 0,07 & -0,95 & 1 & 0 \\ 0,01 & 0,07 & 0,25 & -1,19 & 1 \end{pmatrix} \quad (4.43)$$

Premultiplicando el modelo de la tabla 4.87 por la matriz 4.43 se obtiene el modelo ortogonalizado que representa el modelo periódico, el cual se presenta en la tabla 4.89.

Tabla 4.89: Banco Popular: Modelo VEC(1) ortogonalizado

Variable dependiente	Ecuaciones				
	∇l_t	∇m_t	∇x_t	∇j_t	∇v_t
$ecm1_{t-1}$	1,13	-0,18	-0,30	-0,062	-0,77
$ecm2_{t-1}$	1,08	-0,11	-0,36	-0,95	0,66
$ecm3_{t-1}$	0,96	-0,31	-1,16	-0,035	0,26
$ecm4_{t-1}$	1,13	-1,26	0,078	-0,16	0,48
∇l_t		1,11	-0,069	0,14	-0,012
∇m_t			1,23	-0,066	-0,066
∇x_t				0,95	-0,25
∇j_t					1,19
∇l_{t-1}					0,18
∇m_{t-1}				-0,13	-0,15
∇v_{t-1}		0,12	0,082	0,0031	-0,19

4.A.22 Repsol

4.A.22.1 Relaciones de cointegración

En la tabla 4.90 se muestra la existencia de las relaciones de cointegración.

Tabla 4.90: Repsol: Test de cointegración, método de Engle-Granger

Variable dependiente	$p = 0$
$ecm1_t$	-10,55
$ecm2_t$	-12,14
$ecm3_t$	-14,10
$ecm4_t$	-13,15

Valor crítico(95 %):-5,28

(Phillips y Ouliaris (1990)).

Los gráficos de los residuos de estas relaciones de cointegración se presentan en el gráfico 4.43 , y en él se observa el carácter estacionario de éstas.

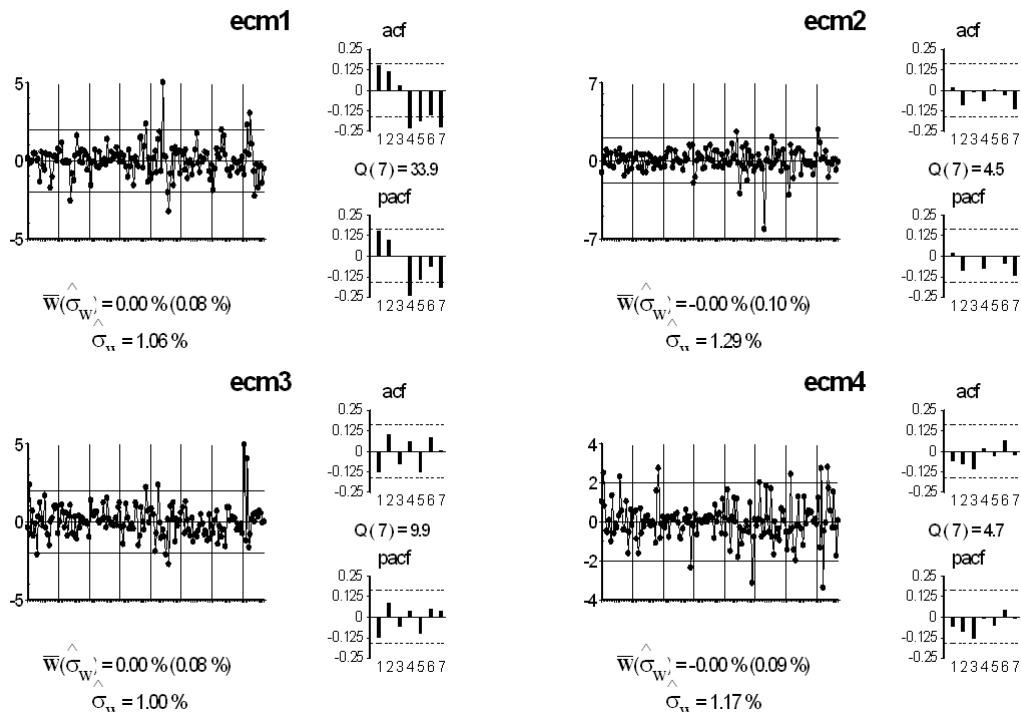


Gráfico 4.43: Repsol: Relaciones de cointegración

4.A.22.2 Estimación modelo VEC

Se estiman todos los parámetros de forma conjunta por mínimos cuadrados generalizados, salvo los de las relaciones de cointegración, que se restringen. Los resultados aparecen en la tabla 4.91.

Tabla 4.91: Repsol: Estimación del VEC(2)

Variable dependiente	Ecuaciones ^a				
	∇l_t	∇m_t	∇x_t	∇j_t	∇v_t
$ecm1_{t-1}$	1,18 (0,15)	1,22 (0,19)	1,22 (0,22)	1,46 (0,27)	0,46 (0,31)
$ecm2_{t-1}$	1,44 (0,14)	1,47 (0,18)	1,48 (0,20)	0,54 (0,24)	0,55 (0,27)
$ecm3_{t-1}$	1,25 (0,15)	1,30 (0,20)	0,26 (0,23)	0,51 (0,29)	0,81 (0,35)
$ecm4_{t-1}$	1,37 (0,13)	0,47 (0,15)	0,34 (0,15)	0,36 (0,12)	
∇l_{t-1}	0,25 (0,09)	0,30 (0,11)	0,35 (0,13)	0,40 (0,17)	0,26 (0,19)
∇m_{t-1}					0,56 (0,14)
∇x_{t-1}					-0,44 (0,13)
∇v_{t-1}	-0,29 (0,12)	-0,42 (0,14)	-0,42 (0,12)	-0,49 (0,17)	-0,40 (0,19)
∇m_{t-2}	0,21 (0,05)	0,041 (0,033)			0,28 (0,08)
∇x_{t-2}	-0,18 (0,05)				-0,28 (0,09)
∇j_{t-2}		-0,098 (0,045)			
∇v_{t-2}	-0,20 (0,09)	-0,23 (0,11)	-0,35 (0,12)	-0,47 (0,16)	-0,40 (0,19)

^aLa tabla muestra los coeficientes estimados del modelo VEC donde cada columna representa una ecuación del mismo. Entre paréntesis se presentan las desviaciones típicas.

La matriz de covarianzas se presenta en (4.44).

$$\Sigma_u = \begin{pmatrix} 1,16E-04 & 1,15E-04 & 9,46E-05 & 1,18E-04 & 1,19E-04 \\ 1,15E-04 & 2,31E-04 & 2,38E-04 & 2,77E-04 & 2,98E-04 \\ 9,46E-05 & 2,38E-04 & 3,34E-04 & 3,90E-04 & 4,08E-04 \\ 1,18E-04 & 2,77E-04 & 3,90E-04 & 6,01E-04 & 6,56E-04 \\ 1,19E-04 & 2,98E-04 & 4,08E-04 & 6,56E-04 & 8,04E-04 \end{pmatrix} \quad (4.44)$$

El gráfico 4.44 muestra los residuos del VEC(2). Por otro lado, en la tabla 4.92 se presentan las funciones de correlación cruzadas. En ninguna de ellas se aprecian correlaciones significativas, por lo que se considera que la forma adecuada de representar la relación entre las variables es el modelo de la tabla 4.91.

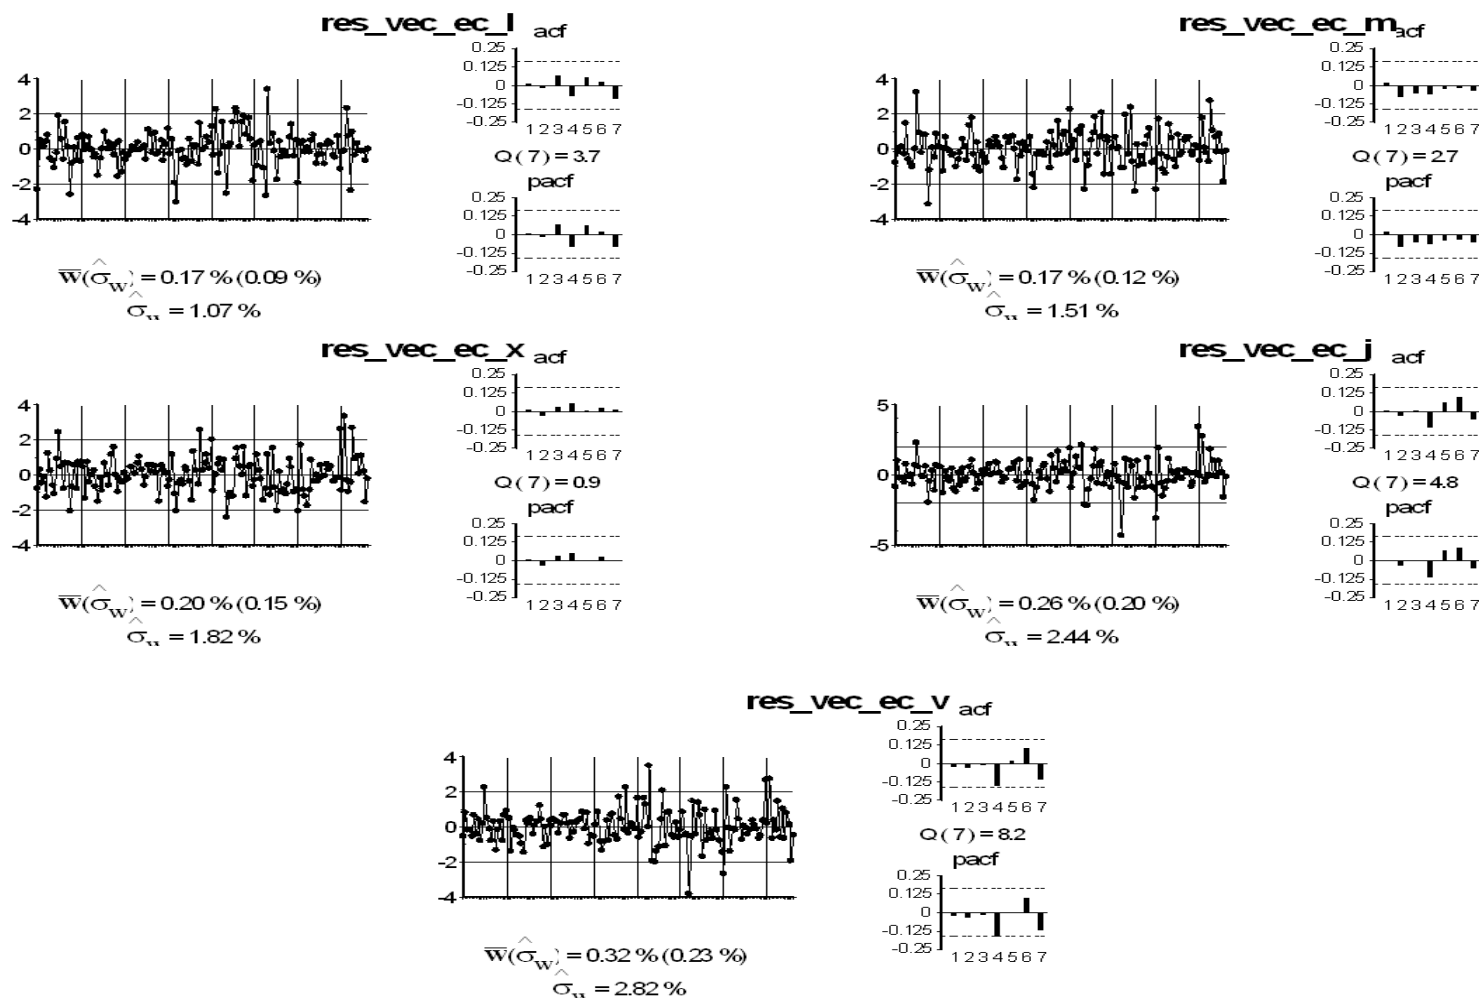


Gráfico 4.44: Repsol: Residuos del VEC(2)

Tabla 4.92: Repsol: Función de correlación cruzada residual del VEC(2)

Retardos	r_{11}	r_{12}	r_{13}	r_{14}	r_{15}
1	0,010	0,052	0,057	0,033	0,011
2	-0,020	-0,055	-0,061	-0,092	-0,056
3	0,069	-0,022	-0,021	0,001	-0,015
4	-0,079	-0,111	-0,053	-0,091	-0,098
5	0,052	0,046	0,008	0,055	0,063
	r_{21}	r_{22}	r_{23}	r_{24}	r_{25}
1	-0,023	0,015	0,010	-0,006	-0,031
2	0,004	-0,082	-0,047	-0,047	-0,039
3	0,006	-0,057	-0,050	-0,041	-0,028
4	-0,020	-0,062	0,010	-0,083	-0,098
5	-0,030	-0,028	0,010	0,087	0,096
	r_{31}	r_{32}	r_{33}	r_{34}	r_{35}
1	-0,035	0,015	0,012	0,005	-0,022
2	0,017	-0,078	-0,034	-0,006	-0,027
3	0,057	0,030	0,030	0,024	0,027
4	0,031	-0,014	0,052	-0,073	-0,100
5	-0,047	-0,019	0,001	0,076	0,090
	r_{41}	r_{42}	r_{43}	r_{44}	r_{45}
1	-0,030	0,006	0,007	0,003	-0,016
2	0,006	-0,057	-0,055	-0,035	-0,038
3	0,041	0,003	0,014	0,005	0,006
4	-0,023	-0,069	-0,017	-0,111	-0,128
5	0,017	0,010	0,007	0,063	0,072
	r_{51}	r_{52}	r_{53}	r_{54}	r_{55}
1	-0,035	-0,009	-0,009	-0,011	-0,026
2	0,018	-0,051	-0,056	-0,042	-0,034
3	-0,003	-0,042	-0,025	-0,026	-0,013
4	-0,009	-0,075	-0,030	-0,128	-0,158
5	0,010	-0,019	-0,035	0,010	0,016

DT = $\frac{2}{\sqrt{T}} = 0,162$. En * significativos al 95 %.

Se necesita ortogonalizar el VEC, para representar de forma correcta el modelo periódico. Para conseguir la matriz A_0 con la que se ortogonaliza el modelo, se utiliza la matriz 4.44.

$$A_0 = \begin{pmatrix} 1 & 0 & 0 & 0 & 0 \\ -0,99 & 1 & 0 & 0 & 0 \\ 0,41 & -1,24 & 1 & 0 & 0 \\ -0,16 & 0,15 & -1,22 & 1 & 0 \\ 0,22 & -0,31 & 0,38 & -1,24 & 1 \end{pmatrix} \quad (4.45)$$

Premultiplicando el modelo de la tabla 4.91 por la matriz 4.45 se obtiene el modelo ortogonalizado que representa el modelo periódico, el cual se presenta en la tabla 4.93.

Tabla 4.93: Repsol: Modelo VEC(2) ortogonalizado

Variable dependiente	Ecuaciones				
	∇l_t	∇m_t	∇x_t	∇j_t	∇v_t
$ecm1_{t-1}$	1,19	0,051	0,20	-0,042	-1,00
$ecm2_{t-1}$	1,44	0,047	0,24	-1,28	0,31
$ecm3_{t-1}$	1,25	0,064	-0,83	0,18	0,15
$ecm4_{t-1}$	1,38	-0,89	0,32	-0,22	-0,13
∇l_t		0,99	-0,41	0,16	-0,22
∇m_t			1,24	-0,15	0,31
∇x_t				1,22	-0,38
∇j_t					1,24
∇l_{t-1}	0,25	0,061	0,073	-0,018	-0,15
∇m_{t-1}					0,56
∇x_{t-1}					-0,46
∇v_{t-1}	-0,29	-0,13	-0,020	0,0075	0,12
∇m_{t-2}	0,21	-0,17	0,037	-0,028	0,31
∇x_{t-2}	-0,18	0,18	-0,075	0,029	-0,32
∇j_{t-2}		-0,098	0,12	-0,015	0,031
∇v_{t-2}	-0,20	-0,024	-0,16	-0,041	0,098

4.A.23 Banco Santander

4.A.23.1 Relaciones de cointegración

En la tabla 4.94 se muestra la existencia de las relaciones de cointegración.

Tabla 4.94: Banco Santander: Test de cointegración, método de Engle-Granger

Variable dependiente	$p = 0$
$ecm1_t$	-10,81
$ecm2_t$	-12,30
$ecm3_t$	-11,07
$ecm4_t$	-13,02

Valor crítico(95 %):-5,28
(Phillips y Ouliaris (1990)).

El gráfico 4.45 muestra los residuos de estas relaciones de cointegración, y en ellos se observa el carácter estacionario de éstas.

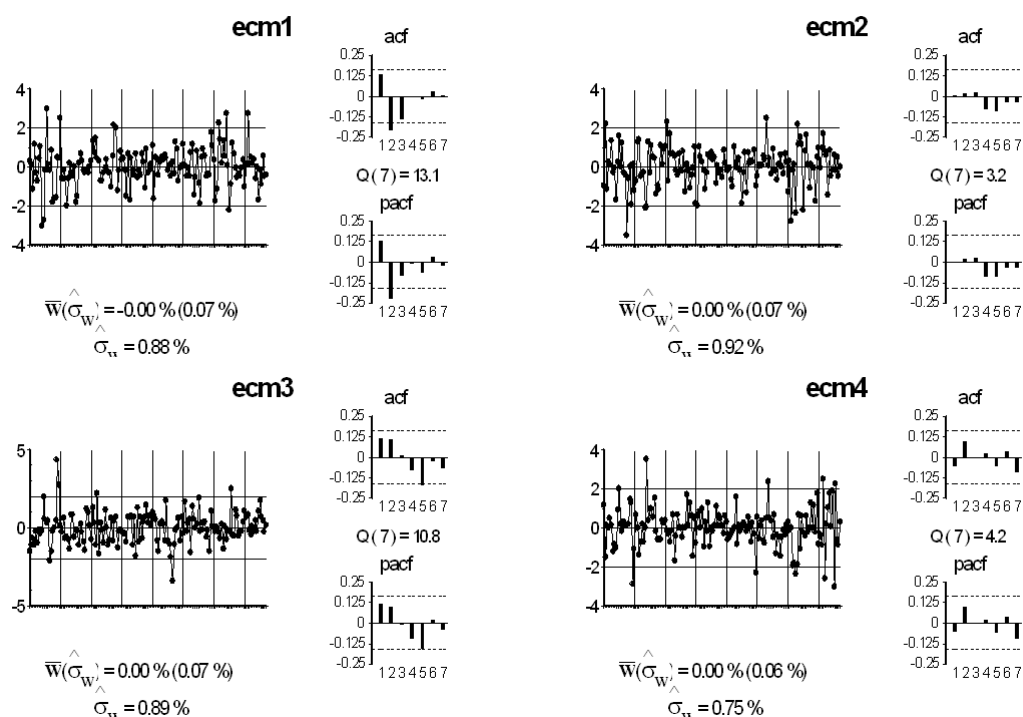


Gráfico 4.45: Banco Santander: Relaciones de cointegración

4.A.23.2 Estimación modelo VEC

Se estiman todos los parámetros de forma conjunta por mínimos cuadrados generalizados, salvo los de las relaciones de cointegración, que se restringen. Los

resultados aparecen en la tabla 4.95.

Tabla 4.95: Banco Santander: Estimación del VEC(1)

Variable dependiente	Ecuaciones ^a				
	∇l_t	∇m_t	∇x_t	∇j_t	∇v_t
μ				0,002 (0,001)	0,003 (0,001)
$ecm1_{t-1}$	1,33 (0,09)	1,28 (0,10)	1,25 (0,10)	1,22 (0,10)	
$ecm2_{t-1}$	1,13 (0,14)	1,15 (0,15)	1,28 (0,15)	0,40 (0,19)	0,49 (0,22)
$ecm3_{t-1}$	0,90 (0,10)	0,97 (0,12)	0,28 (0,14)	0,34 (0,18)	0,48 (0,20)
$ecm4_{t-1}$	1,34 (0,12)	0,30 (0,14)	0,57 (0,17)	0,75 (0,21)	0,57 (0,22)
∇l_{t-1}			0,10 (0,05)	0,13 (0,05)	
∇m_{t-1}					0,26 (0,08)
∇x_{t-1}	0,11 (0,08)	0,09 (0,07)			
∇j_{t-1}	-0,17 (0,10)	-0,18 (0,10)	-0,32 (0,09)	-0,42 (0,10)	-0,85 (0,14)
∇v_{t-1}					0,35 (0,10)

^aLa tabla muestra los coeficientes estimados del modelo VEC donde cada columna representa una ecuación del mismo. Entre paréntesis se presentan las desviaciones típicas.

La matriz de covarianzas se presenta en (4.46).

$$\Sigma_u = \begin{pmatrix} 1,13E-04 & 1,04E-04 & 8,60E-05 & 9,93E-05 & 1,01E-04 \\ 1,04E-04 & 1,51E-04 & 1,37E-04 & 1,48E-04 & 1,38E-04 \\ 8,60E-05 & 1,37E-04 & 1,96E-04 & 2,06E-04 & 1,92E-04 \\ 9,93E-05 & 1,48E-04 & 2,06E-04 & 2,99E-04 & 2,99E-04 \\ 1,01E-04 & 1,38E-04 & 1,92E-04 & 2,99E-04 & 3,67E-04 \end{pmatrix} \quad (4.46)$$

En la tabla 4.96 se presentan las funciones de correlación cruzadas. Ninguna de ellas es estadísticamente distinta de 0, por lo que se considera que el modelo de la tabla 4.95 representa de forma adecuada la relación entre las variables. Por su parte, los residuos del VEC(1) aparecen en el gráfico 4.46.

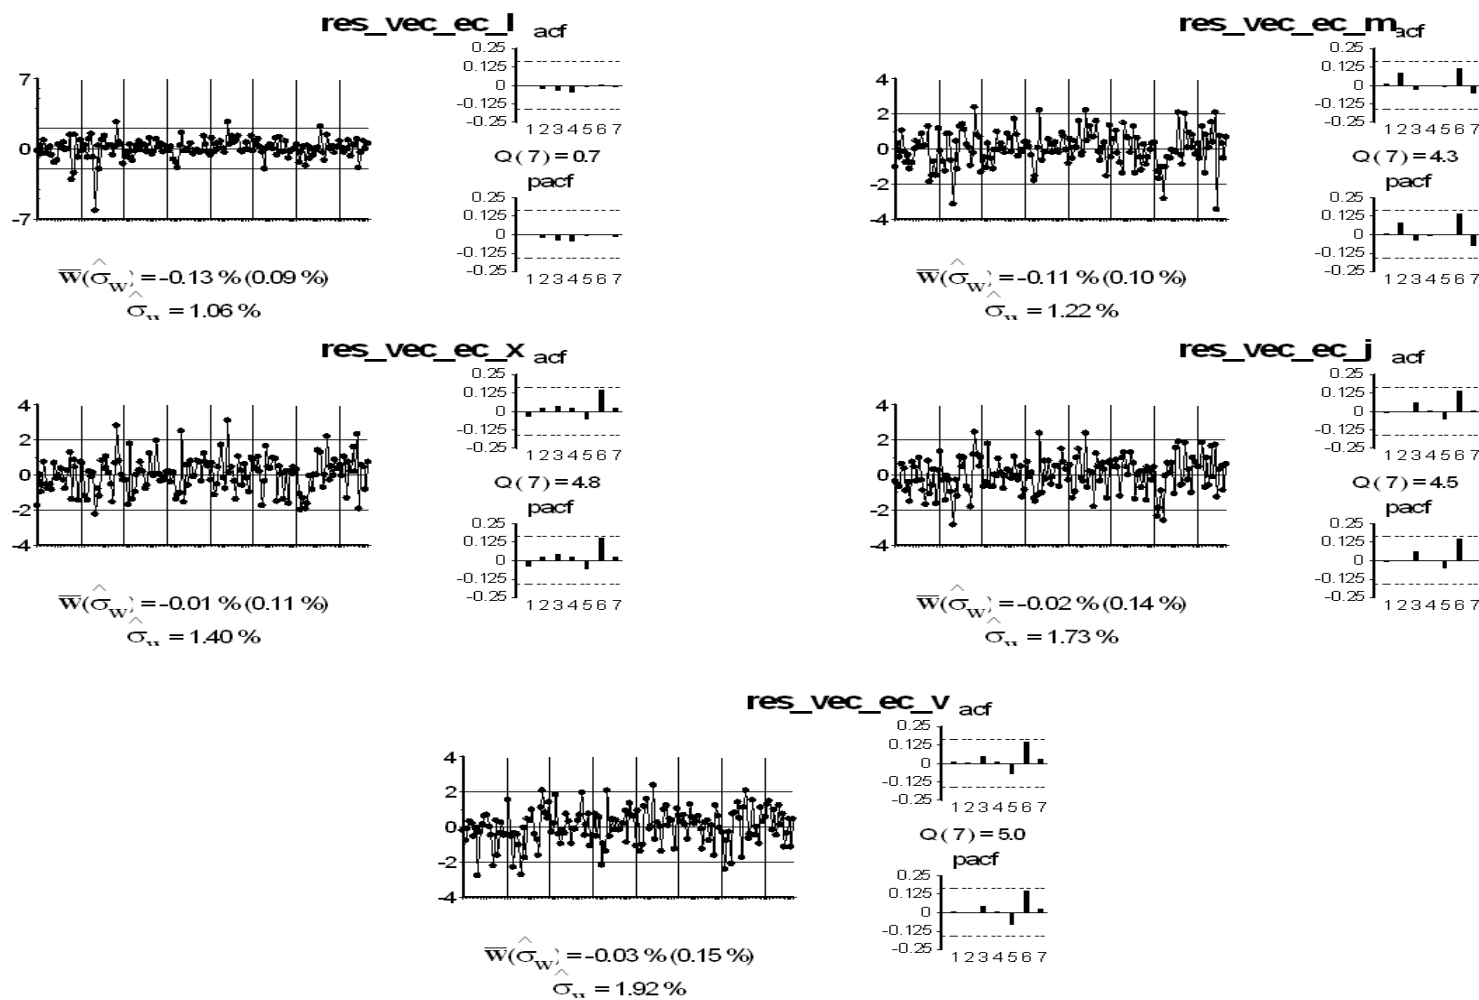


Gráfico 4.46: Banco Santander: Residuos del VEC(1)

Tabla 4.96: Banco Santander: Función de correlación cruzada residual del VEC(1)

Retardos	r_{11}	r_{12}	r_{13}	r_{14}	r_{15}
1	-0,003	0,004	0,004	0,010	0,029
2	-0,025	0,005	0,009	0,022	0,013
3	-0,042	-0,025	0,008	0,067	0,090
4	-0,044	0,009	0,116	0,105	0,127
5	-0,010	0,055	0,044	0,003	0,006
	r_{21}	r_{22}	r_{23}	r_{24}	r_{25}
1	-0,001	0,013	0,013	0,010	0,030
2	0,030	0,084	0,025	0,027	0,007
3	-0,050	-0,034	-0,018	0,037	0,039
4	-0,059	-0,007	0,065	0,114	0,139
5	-0,046	-0,008	-0,025	-0,034	-0,050
	r_{31}	r_{32}	r_{33}	r_{34}	r_{35}
1	-0,043	-0,023	-0,037	-0,043	-0,031
2	0,037	0,083	0,024	0,022	0,021
3	0,020	0,025	0,042	0,079	0,048
4	-0,095	-0,031	0,023	0,075	0,110
5	-0,020	0,007	-0,057	-0,049	-0,047
	r_{41}	r_{42}	r_{43}	r_{44}	r_{45}
1	-0,030	-0,019	-0,015	-0,014	0,010
2	-0,016	0,008	-0,013	-0,005	-0,010
3	0,057	-0,004	0,018	0,063	0,089
4	-0,142	-0,107	-0,034	0,001	0,028
5	-0,016	-0,011	-0,032	-0,054	-0,063
	r_{51}	r_{52}	r_{53}	r_{54}	r_{55}
1	-0,035	-0,026	-0,019	-0,016	0,009
2	-0,008	0,004	-0,016	0,003	0,003
3	0,079	0,001	0,012	0,034	0,049
4	-0,110	-0,112	-0,040	-0,013	0,013
5	-0,019	0,019	-0,011	-0,063	-0,078

DT = $\frac{2}{\sqrt{T}} = 0,161$. En * significativos al 95 %.

Se necesita ortogonalizar el VEC, para representar de forma correcta el modelo periódico. Para conseguir la matriz A_0 con la que se ortogonaliza el modelo, se utiliza la matriz 4.46.

$$A_0 = \begin{pmatrix} 1 & 0 & 0 & 0 & 0 \\ -0,92 & 1 & 0 & 0 & 0 \\ 0,21 & -1,05 & 1 & 0 & 0 \\ -0,14 & 0,04 & -1,01 & 1 & 0 \\ -0,16 & 0,12 & 0,24 & -1,18 & 1 \end{pmatrix} \quad (4.47)$$

Premultiplicando el modelo de la tabla 4.95 por la matriz 4.47 se obtiene el modelo ortogonalizado que representa el modelo periódico, el cual se presenta en la tabla 4.97.

Tabla 4.97: Banco Santander: Modelo VEC(1) ortogonalizado

Variable dependiente	Ecuaciones				
	∇l_t	∇m_t	∇x_t	∇j_t	∇v_t
μ				0,0020	0,0006
$ecm1_{t-1}$	1,33	0,049	0,18	-0,18	-1,20
$ecm2_{t-1}$	1,13	0,11	0,31	-1,01	0,29
$ecm3_{t-1}$	0,90	0,13	-0,55	-0,029	0,12
$ecm4_{t-1}$	1,34	-0,94	0,54	-0,0007	-0,36
∇l_t		0,92	-0,21	0,14	0,16
∇m_t			1,05	-0,040	-0,12
∇x_t				1,01	-0,24
∇j_t					1,18
∇l_{t-1}			0,11	0,029	-0,13
∇m_{t-1}					0,26
∇x_{t-1}	0,11	-0,016	-0,070	-0,013	-0,0072
∇j_{t-1}	-0,17	-0,024	-0,17	-0,073	-0,43
∇v_{t-1}					0,35

4.A.24 Telefónica

4.A.24.1 Relaciones de cointegración

Se muestra la existencia de las relaciones de cointegración en la tabla 4.98.

Tabla 4.98: Telefónica: Test de cointegración, método de Engle-Granger

Variable dependiente	$p = 0$
$ecm1_t$	-12,13
$ecm2_t$	-11,39
$ecm3_t$	-14,10
$ecm4_t$	-13,15

Valor crítico(95 %):-5,28
(Phillips y Ouliaris (1990)).

Los residuos de estas relaciones de cointegración se presentan en el gráfico 4.47 , y en ellos se observa el carácter estacionario de éstas.

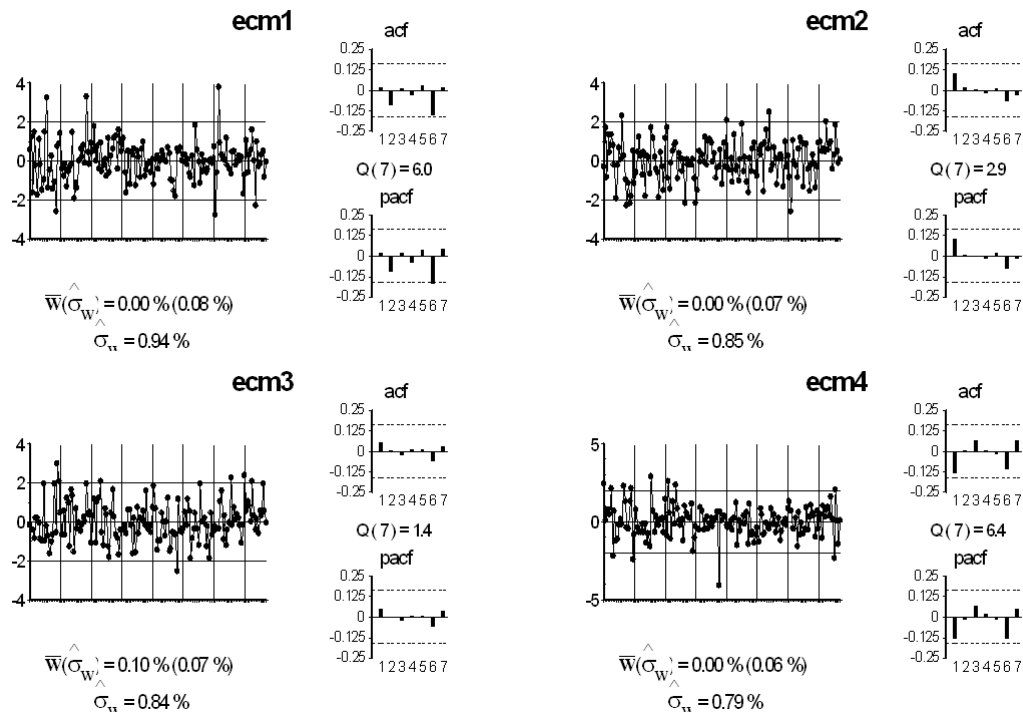


Gráfico 4.47: Telefónica: Relaciones de cointegración

4.A.24.2 Estimación modelo VEC

Se estiman todos los parámetros de forma conjunta por mínimos cuadrados generalizados, menos los de las relaciones de cointegración, que se restringen. Los resultados aparecen en la tabla 4.99.

Tabla 4.99: Telefónica: Estimación del VEC(1)

Variable dependiente	Ecuaciones ^a				
	∇l_t	∇m_t	∇x_t	∇j_t	∇v_t
μ				0,001 (0,000)	
$ecm1_{t-1}$	1,28 (0,10)	1,31 (0,13)	1,26 (0,16)	1,35 (0,21)	0,59 (0,25)
$ecm2_{t-1}$	1,20 (0,11)	1,50 (0,14)	1,46 (0,18)	0,71 (0,22)	0,84 (0,27)
$ecm3_{t-1}$	0,92 (0,11)	1,06 (0,13)	0,22 (0,16)	0,34 (0,20)	0,61 (0,25)
$ecm4_{t-1}$	1,05 (0,10)		0,20 (0,13)	0,27 (0,17)	0,55 (0,23)
∇l_{t-1}	-0,14 (0,07)	-0,14 (0,06)			
∇m_{t-1}	0,14 (0,07)	0,15 (0,06)			
∇v_{t-1}	-0,066 (0,078)	-0,21 (0,09)	-0,26 (0,11)	-0,38 (0,14)	-0,58 (0,18)

^aLa tabla muestra los coeficientes estimados del modelo VEC donde cada columna representa una ecuación del mismo. Entre paréntesis se presentan las desviaciones típicas.

La matriz de covarianzas se presenta en (4.48).

$$\Sigma_u = \begin{pmatrix} 6,46E-05 & 5,97E-05 & 5,77E-05 & 6,21E-05 & 6,50E-05 \\ 5,97E-05 & 1,11E-04 & 1,10E-04 & 1,16E-04 & 1,15E-04 \\ 5,77E-05 & 1,10E-04 & 1,77E-04 & 1,91E-04 & 1,98E-04 \\ 6,21E-05 & 1,16E-04 & 1,91E-04 & 2,74E-04 & 2,95E-04 \\ 6,50E-05 & 1,15E-04 & 1,98E-04 & 2,95E-04 & 4,01E-04 \end{pmatrix} \quad (4.48)$$

Los residuos del VEC(1) aparecen en el gráfico 4.48. Por otro lado, en la tabla 4.100 se presentan las funciones de correlación cruzadas. Tres de ellas son significativas, sin embargo, se considera que el modelo de la tabla 4.99 representa de forma adecuada la relación entre las variables.

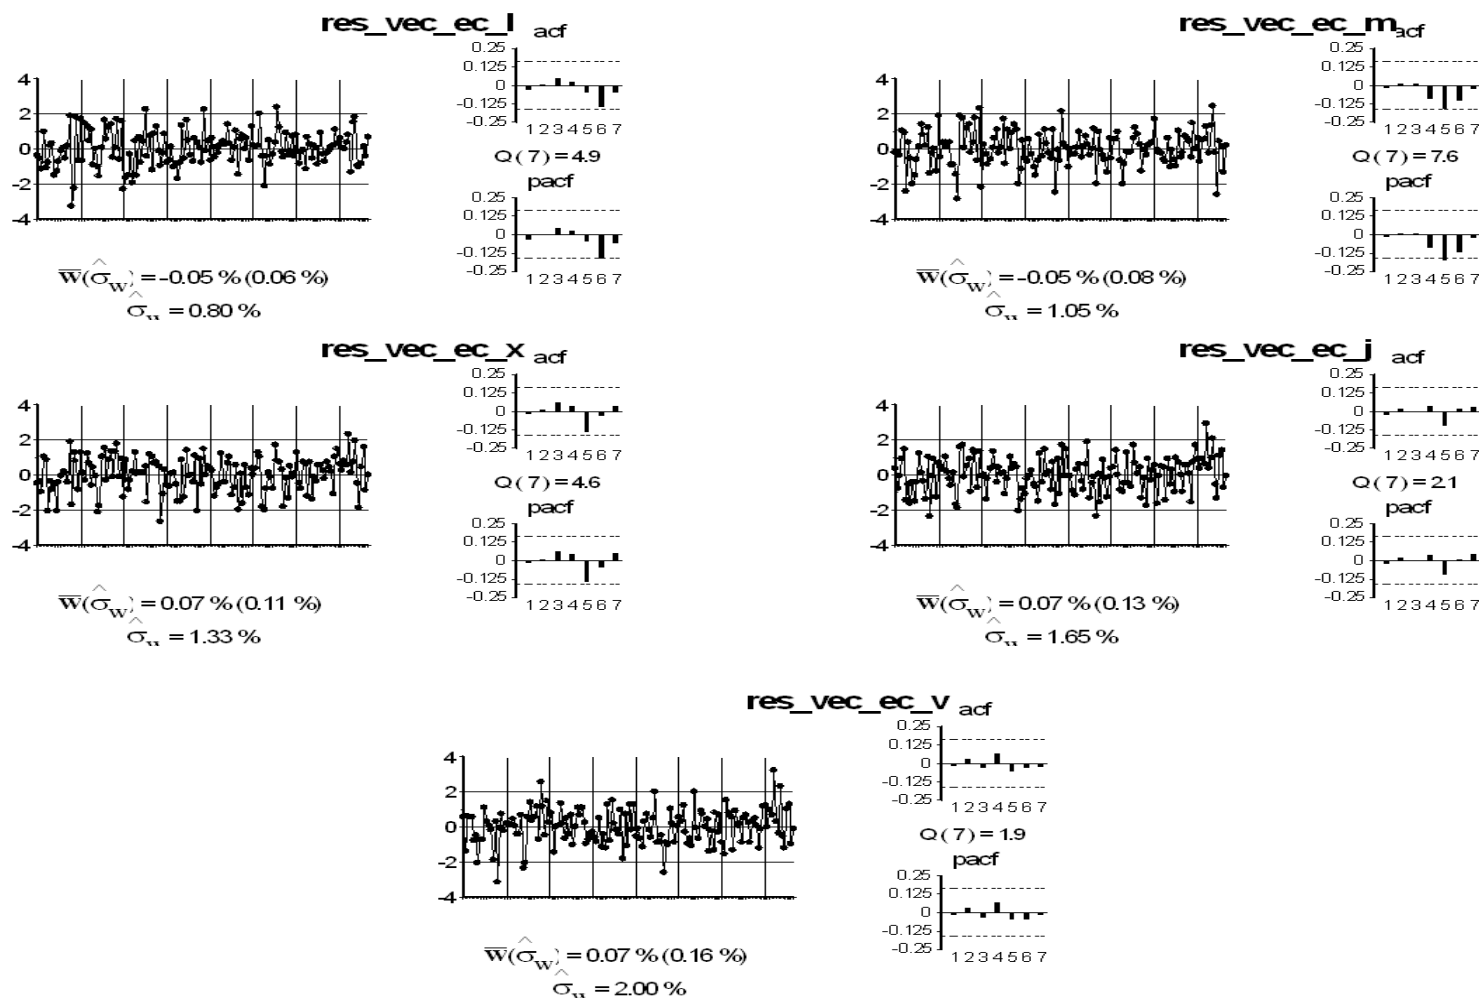


Gráfico 4.48: Telefónica: Residuos del VEC(1)

Tabla 4.100: Telefónica: Función de correlación cruzada residual - Modelo VEC(1)

Retardos	r_{11}	r_{12}	r_{13}	r_{14}	r_{15}
1	-0,029	-0,014	-0,001	0,000	0,001
2	0,002	0,012	0,044	0,066	0,064
3	0,044	0,025	0,048	0,088	0,060
4	0,022	-0,052	-0,088	-0,081	-0,049
5	-0,047	-0,132	-0,070	-0,118	-0,141
	r_{21}	r_{22}	r_{23}	r_{24}	r_{25}
1	-0,033	-0,021	-0,005	-0,005	-0,002
2	-0,016	0,014	0,031	0,070	0,063
3	-0,009	0,012	0,077	0,099	0,133
4	-0,056	-0,088	-0,092	-0,091	-0,047
5	-0,082	-0,165*	-0,134	-0,159	-0,159
	r_{31}	r_{32}	r_{33}	r_{34}	r_{35}
1	-0,043	-0,025	-0,019	-0,024	-0,021
2	-0,015	0,013	0,013	0,040	0,064
3	0,019	0,005	0,060	0,030	0,030
4	0,040	0,070	0,041	0,038	0,065
5	-0,086	-0,180*	-0,142	-0,131	-0,127
	r_{41}	r_{42}	r_{43}	r_{44}	r_{45}
1	-0,031	-0,033	-0,018	-0,024	-0,024
2	-0,054	-0,009	-0,010	0,021	0,028
3	0,033	-0,068	0,013	-0,005	0,008
4	-0,014	-0,009	0,049	0,037	0,051
5	-0,087	-0,171*	-0,109	-0,095	-0,092
	r_{51}	r_{52}	r_{53}	r_{54}	r_{55}
1	-0,012	-0,019	-0,012	-0,016	-0,017
2	-0,043	0,012	0,022	0,045	0,035
3	0,028	-0,067	-0,014	-0,062	-0,035
4	0,064	0,054	0,077	0,069	0,068
5	-0,061	-0,131	-0,072	-0,059	-0,052

DT= $\frac{2}{\sqrt{T}}$ = 0,161. En * significativos al 95 %.

Se necesita ortogonalizar el VEC, para representar de forma correcta el modelo periódico. Para conseguir la matriz A_0 con la que se ortogonaliza el modelo, se utiliza la matriz 4.48.

$$A_0 = \begin{pmatrix} 1 & 0 & 0 & 0 & 0 \\ -0,93 & 1 & 0 & 0 & 0 \\ 0,03 & -1,00 & 1 & 0 & 0 \\ -0,02 & 0,04 & -1,10 & 1 & 0 \\ -0,11 & 0,18 & 0,09 & -1,19 & 1 \end{pmatrix} \quad (4.49)$$

Premultiplicando el modelo de la tabla 4.99 por la matriz 4.49 se obtiene el modelo ortogonalizado que representa el modelo periódico, el cual se presenta en la tabla 4.101.

Tabla 4.101: Telefónica: Modelo VEC(1) ortogonalizado

Variable dependiente	Ecuaciones				
	∇l_t	∇m_t	∇x_t	∇j_t	∇v_t
μ				0,0010	-0,0012
$ecm1_{t-1}$	1,28	0,13	-0,014	0,0026	-0,82
$ecm2_{t-1}$	1,20	0,39	-0,0050	-0,85	0,26
$ecm3_{t-1}$	0,92	0,21	-0,82	0,14	0,31
$ecm4_{t-1}$	1,05	-0,97	0,23	0,024	0,13
∇l_t		0,93	-0,025	0,016	0,11
∇m_t			1,00	-0,043	-0,18
∇x_t				1,10	-0,091
∇j_t					1,19
∇l_{t-1}	-0,14	-0,010	0,13	-0,0038	-0,0093
∇m_{t-1}	0,14	0,023	-0,15	0,0043	0,011
∇v_{t-1}	-0,14	-0,074	-0,060	-0,099	-0,17

4.A.25 Unión Fenosa

4.A.25.1 Relaciones de cointegración

En la tabla 4.98 se muestra la existencia de estas relaciones de cointegración.

Tabla 4.102: Unión Fenosa: Test de cointegración, método de Engle-Granger

Variable dependiente	$p = 0$
$ecm1_t$	-13,78
$ecm2_t$	-11,34
$ecm3_t$	-13,32
$ecm4_t$	-12,25

Valor crítico(95 %):-5,28

(Phillips y Ouliaris (1990)).

Los gráficos de los residuos de estas relaciones de cointegración se presentan

en el gráfico 4.49, y en ellos se observa el carácter estacionario de éstas.

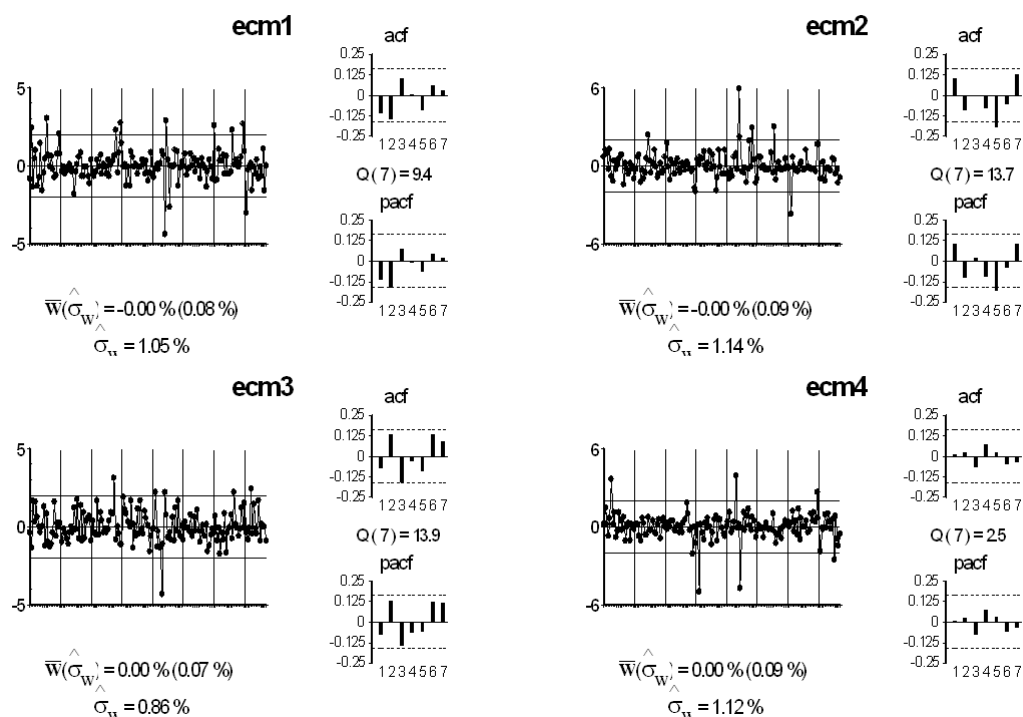


Gráfico 4.49: Unión Fenosa: Relaciones de cointegración

4.A.25.2 Estimación modelo VEC

Se estiman todos los parámetros de forma conjunta por mínimos cuadrados generalizados, salvo los de las relaciones de cointegración, que se restringen. Los resultados aparecen en la tabla 4.103.

Tabla 4.103: Unión Fenosa: Estimación del VEC(0)

Variable dependiente	Ecuaciones ^a				
	∇l_t	∇m_t	∇x_t	∇j_t	∇v_t
μ				0,002 (0,000)	0,003 (0,000)
$ecm1_{t-1}$	1,08 (0,09)	1,18 (0,09)	1,21 (0,08)	1,15 (0,07)	
$ecm2_{t-1}$	1,01 (0,08)	0,82 (0,07)	0,92 (0,06)		
$ecm3_{t-1}$	1,17 (0,10)	1,06 (0,07)			
$ecm4_{t-1}$	1,05 (0,06)				

^aLa tabla muestra los coeficientes estimados del modelo VEC donde cada columna representa una ecuación del mismo. Entre paréntesis se presentan las desviaciones típicas.

La matriz de covarianzas se presenta en (4.50).

$$\Sigma_u = \begin{pmatrix} 1,61E-04 & 1,42E-04 & 1,32E-04 & 1,40E-04 & 1,40E-04 \\ 1,42E-04 & 2,39E-04 & 2,33E-04 & 2,48E-04 & 2,51E-04 \\ 1,32E-04 & 2,33E-04 & 3,02E-04 & 3,36E-04 & 3,25E-04 \\ 1,40E-04 & 2,48E-04 & 3,36E-04 & 4,99E-04 & 4,82E-04 \\ 1,40E-04 & 2,51E-04 & 3,25E-04 & 4,82E-04 & 5,74E-04 \end{pmatrix} \quad (4.50)$$

Los residuos del VEC(0) aparecen en el gráfico 4.50. Por otro lado, en la tabla 4.104 se presentan las funciones de correlación cruzadas. En tres de ellas se aprecian correlaciones significativas, sin embargo, se considera que el modelo de la tabla 4.103 representa de forma adecuada la correlación dinámica entre las variables.

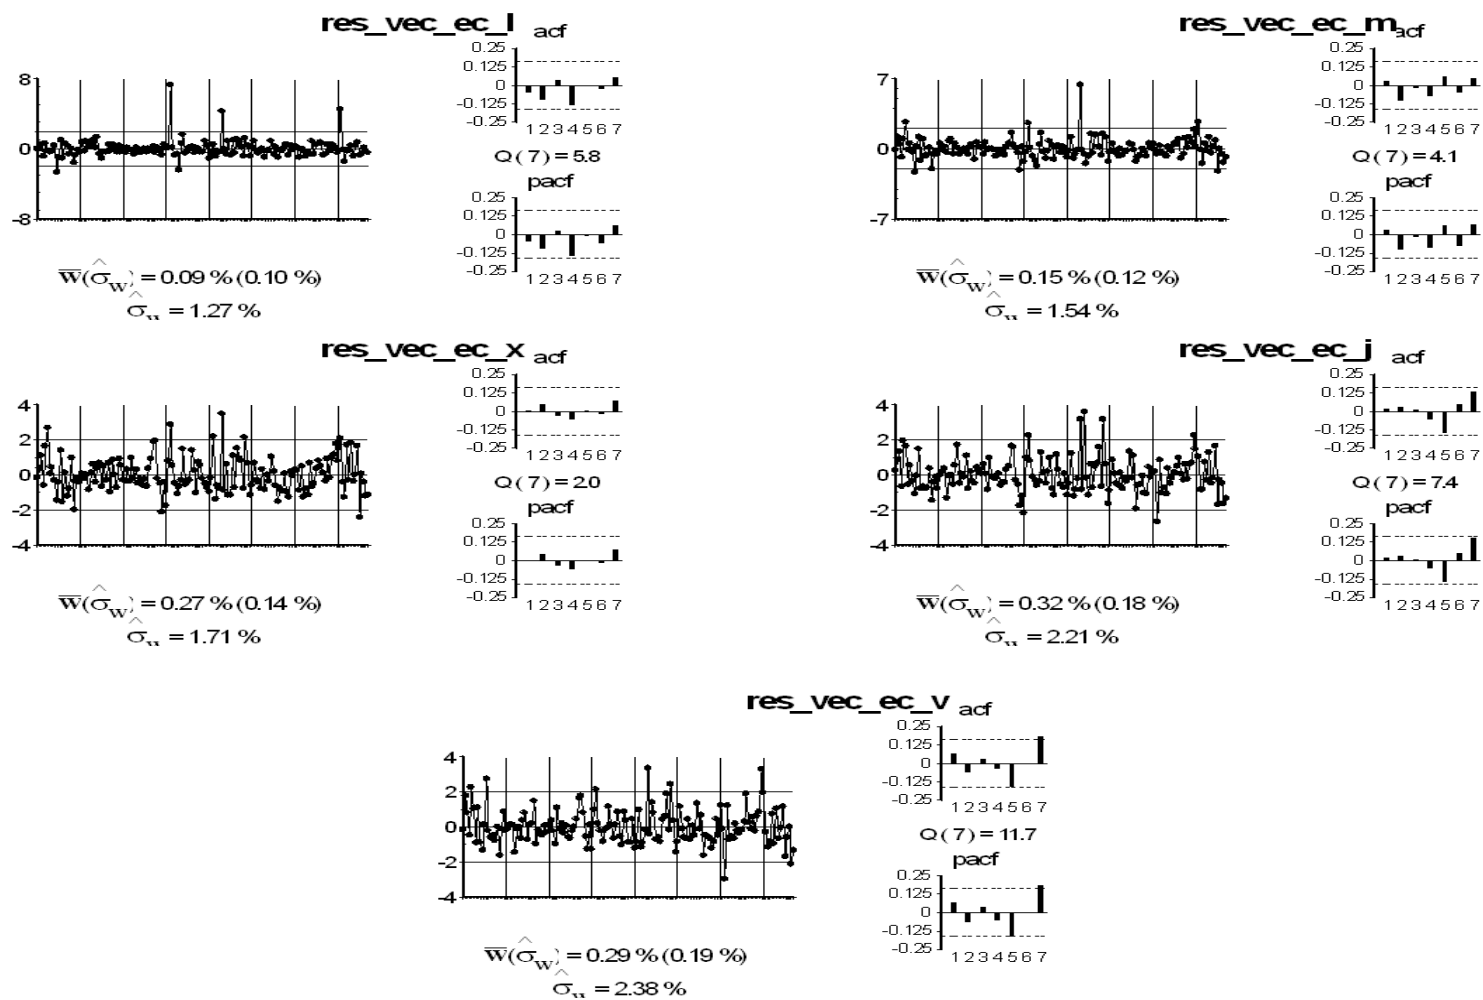


Gráfico 4.50: Unión Fenosa: Residuos del VEC(0)

Tabla 4.104: Unión Fenosa: Función de correlación cruzada residual - Modelo VEC(0)

Retardos	r_{11}	r_{12}	r_{13}	r_{14}	r_{15}
1	-0,047	-0,013	-0,015	-0,001	0,033
2	-0,099	-0,132	-0,126	-0,148	-0,046
3	0,038	0,078	-0,007	-0,004	0,063
4	-0,138	-0,190*	-0,158	-0,144	-0,111
5	-0,003	-0,053	-0,053	-0,041	-0,084
	r_{21}	r_{22}	r_{23}	r_{24}	r_{25}
1	-0,043	0,030	0,024	0,027	0,062
2	-0,112	-0,102	-0,053	-0,087	-0,049
3	-0,054	-0,022	-0,055	-0,015	-0,018
4	-0,071	-0,075	-0,066	-0,074	-0,060
5	0,086	0,061	0,038	0,026	-0,040
	r_{31}	r_{32}	r_{33}	r_{34}	r_{35}
1	-0,057	0,010	0,000	0,001	0,041
2	-0,051	-0,027	0,046	-0,012	0,015
3	0,036	0,044	-0,030	-0,015	-0,027
4	-0,019	-0,057	-0,057	-0,049	-0,045
5	0,084	0,042	0,003	-0,003	-0,047
	r_{41}	r_{42}	r_{43}	r_{44}	r_{45}
1	-0,027	0,038	0,013	0,018	0,061
2	0,065	0,113	0,122	0,033	0,039
3	0,048	0,088	0,007	0,010	0,016
4	0,014	-0,019	-0,039	-0,053	-0,072
5	-0,006	-0,074	-0,120	-0,146	-0,175*
	r_{51}	r_{52}	r_{53}	r_{54}	r_{55}
1	-0,075	0,022	0,010	0,024	0,066
2	-0,034	0,014	0,053	-0,043	-0,062
3	0,024	0,110	0,019	0,011	0,033
4	0,013	-0,007	-0,025	-0,024	-0,043
5	-0,011	-0,080	-0,077	-0,115	-0,161*

DT = $\frac{2}{\sqrt{T}} = 0,161$. En * significativos al 95 %.

Se necesita ortogonalizar el VEC, para representar de forma correcta el modelo periódico. Para conseguir la matriz A_0 con la que se ortogonaliza el modelo, se utiliza la matriz 4.50.

$$A_0 = \begin{pmatrix} 1 & 0 & 0 & 0 & 0 \\ -0,88 & 1 & 0 & 0 & 0 \\ 0,08 & -1,02 & 1 & 0 & 0 \\ -0,02 & 0,21 & -1,27 & 1 & 0 \\ 0,06 & -0,22 & 0,15 & -0,97 & 1 \end{pmatrix} \quad (4.51)$$

Premultiplicando el modelo de la tabla 4.103 por la matriz 4.51 se obtiene el modelo ortogonalizado que representa el modelo periódico, el cual se presenta en la tabla 4.105.

Tabla 4.105: Unión Fenosa: Modelo VEC(0) ortogonalizado

Variable dependiente	Ecuaciones				
	∇l_t	∇m_t	∇x_t	∇j_t	∇v_t
μ				0,0020	0,0011
$ecm1_{t-1}$	1,08	0,23	0,097	-0,16	-1,14
$ecm2_{t-1}$	1,01	-0,074	0,17	-1,01	0,014
$ecm3_{t-1}$	1,17	0,027	-0,99	0,20	-0,17
$ecm4_{t-1}$	1,05	-0,92	0,083	-0,020	0,058
∇l_t		0,99	-0,080	0,019	-0,055
∇m_t			1,02	-0,21	0,22
∇x_t				1,27	0,15
∇j_t					0,97

Capítulo 5

Conclusiones y Extensiones

5.1 Conclusiones

Al repasar la literatura aparece un gran número de variables que se pueden modelizar mediante modelos periódicos. Si la forma más correcta de representar la dinámica de estas variables es la forma periódica, es de esperar, que este tipo de modelos generen mejores previsiones que cualquier otra especificación, entre ellas la modelización AR lineal.

En esta Tesis se investiga la capacidad del contraste de estacionalidad univariante desarrollado por Flores y Novales (1997) para detectar la presencia de comportamientos periódicos. Sobre la serie del IBEX-35 y de 24 de sus componentes se estudia, si el contraste es capaz de seleccionar cuándo una variable se puede modelizar con una especificación periódica. Se analiza la precisión de las previsiones de este tipo de modelos y se proponen diferentes mejoras para incrementar su capacidad predictiva.

En un primer experimento se comparan modelos periódicos sin restringir con modelos AR lineales. Se utiliza el contraste de estacionalidad para seleccionar las variables modelizadas con una especificación periódica. En este caso, el contraste concluye que sólo 3 de las 25 series vienen generadas por un modelo AR, al 95 % de confianza. Estas 3 variables son: Acciona, Ferrovial e Iberdrola. Este resultado hace

que en 22 series se haya seleccionado el modelo periódico como correcto, es decir, el 88 % del total de variables estudiadas.

Sin embargo, al estudiar la capacidad predictiva de los modelos seleccionados, el contraste no detecta bien el modelo que mejor prevé. Se comienza calculando las previsiones de cada uno de los modelos dentro de la muestra. En 2 de los 3 casos seleccionados como AR, éste es el modelo que mejor prevé. Estos dos casos son Ferrovial e Iberdrola. En cambio, para Acciona, las mejores previsiones intramuestrales las consigue el modelo periódico.

Por su parte, en las 22 series donde se ha seleccionado el modelo periódico, éste es el que mejores previsiones obtiene dentro de la muestra.

Hasta aquí, salvo por el caso de Acciona, el contraste ha demostrado ser una buena herramienta.

Al calcular las previsiones extramuestrales de las tres series modelizadas con un especificación autorregresiva, estos modelos son los que consiguen mejores previsiones fuera de la muestra. El problema surge al calcular las previsiones extramuestrales de los 22 modelos donde se ha detectado comportamiento periódico. Sólo en 2 de los 22 modelos periódicos seleccionados, los correspondientes a FCC y Repsol, la especificación periódica prevé mejor que los modelos AR. En los 20 casos restantes, el modelo AR prevé mejor que el periódico.

Estos resultados indican que el contraste de estacionalidad tiene buen tamaño para detectar cuando las variables no tienen comportamiento periódico, ya que para las 3 variables para las que no se rechaza la hipótesis nula, selecciona bien el modelo que mejor prevé fuera de la muestra. Sin embargo, la potencia del contraste es muy pobre, ya que en los 22 casos donde se ha rechazado la hipótesis nula y se ha seleccionado el modelo periódico, sólo en 2 de ellos se ha obtenido que este modelo es el que mejores previsiones extramuestrales obtiene.

Al comprobar la posibilidad de construir modelos periódicos, en sólo 8 de los 25 casos es posible. Se puede construir modelos compuestos para los 3 casos

señalizados como modelos AR. Sin embargo, sólo en 2 de los 8 casos, BBVA y Repsol, ambos señalizados como modelos periódicos por el contraste, las previsiones del modelo compuesto mejoran a las de los modelos simples.

A la vista de los resultados, ni el contraste parece una buena herramienta para detectar comportamiento periódico por su escasa potencia, ni la decisión de construir los modelos compuestos eligiendo para cada día aquel modelo que mejor prevé dentro de la muestra parece ser una buena idea.

Se sospecha que la gran diferencia entre los resultados obtenidos para dentro y fuera de la muestra puede deberse a problemas de sobreparametrización. Esto motiva un segundo experimento, donde se restringuen los modelos periódicos.

Los resultados en este segundo experimento cambian notablemente. Al aplicar el contraste, al 95 % de confianza, se obtienen 8 variables donde el modelo seleccionado es el AR. Estas variables son: Abertis, Acerinox, Altadis, Acciona, Ferrovial, Gamesa, Iberia e Indra. Ahora el 68 % de las variables se identifican como periódicas frente al 88 % del anterior experimento.

Para los 8 casos señalizados como modelos AR, este modelo es el que mejores previsiones intramuestrales obtiene. De igual modo, las 17 variables donde se detecta comportamiento periódico, la mejor previsión intramuestral la consigue el modelo periódico.

Fuera de la muestra, en los 8 casos seleccionados como autorregresivos, este tipo de modelos es superior a la hora de calcular las previsiones. Además, el modelo AR es el mejor modelo para prever todos los días de la semana. Esto hace que no se puedan construir modelos compuestos para las 8 variables donde se ha seleccionado el modelo AR.

En los 17 casos donde se detecta comportamiento periódico, en 7 de ellos éste es el modelo que mejor prevé. Estas 7 variables son: IBEX-35, Banesto, Endesa, FCC, Banco Popular, Repsol y Unión Fenosa. Este resultado muestra que la potencia del contraste ha mejorado notablemente, pasando del 9 % al 41 %.

Sin embargo, el resultado más importante se obtiene a la hora de estudiar los modelos compuestos. Al restringir los modelos periódicos ahora se pueden construir 9 modelos compuestos. Estos modelos siempre prevén mejor que los modelos simples.

Al realizar este segundo experimento se ha obtenido un resultado importante. Restringiendo los modelos periódicos, el contraste es una herramienta a tener en cuenta para la selección de modelos. Cuando el contraste no rechaza la hipótesis nula, los modelos AR son aquellos que mejor prevén tanto dentro como fuera de la muestra. Además, estos modelos son los que mejor prevén todos los días, de tal manera, que no se pueden construir modelos compuestos.

Cuando se rechaza la hipótesis nula, ahora en 13 de los 17 casos donde no se ha seleccionado el modelo AR, es el modelo periódico o el modelo compuesto el que mejor prevé. Es decir, en el 76 % de los casos, el contraste acierta al rechazar la hipótesis nula.

Finalmente, en todos los casos donde se ha podido construir modelo compuesto, este modelo es el que mejor prevé. Esto indica que el criterio elegido para construirlos es correcto, y las características intramuestrales de las variables se trasladan fuera de la muestra.

Como conclusión final, se debe señalar la vital importancia de la restricción de los modelos periódicos, para que el contraste de Flores y Novales (1997) pueda detectar la presencia de comportamientos periódicos, y que esto se pueda traducir en mejoras en la capacidad predictiva de los modelos.

5.2 Extensiones

La selección de las variables objeto de estudio, se ha visto afectada por la discusión del efecto día de la semana.

Si se centra la atención dentro de la Bolsa española, hay varios trabajos de principios de los noventa que defienden la existencia de este efecto.

Por citar sólo un par de ellos, Rubio (1991) encuentra que los lunes presentan un rendimiento medio superior y significativo para datos comprendidos entre 1984 y 1988. Lo mismo encuentra Martínez Abascal (1993) para datos entre 1985 y 1989. Esto contrasta con lo encontrado hasta la fecha en otros países, donde el rendimiento de los viernes tiende a ser más elevado, mientras que el rendimiento de los lunes tiende a ser anormalmente bajo.

Estos dos trabajos utilizan datos anteriores al 29 de julio de 1989. En esta fecha se introdujo la Ley del Mercado de Valores, momento en que comenzó a funcionar el mercado continuo.

En el trabajo de Peña (1995) se defiende que la introducción de las anteriores reformas eliminan el anterior efecto lunes. El autor llega a la conclusión que este efecto día de semana en la Bolsa española se debía a la falta de eficiencia del mercado.

Sin embargo, en trabajos más reciente, sí que aparece efecto día de la semana. Caceres et al. (2006), introduciendo variables ficticias, tanto para explicar el rendimiento medio como la varianza condicionada, encuentran que el IBEX-35 tiene un comportamiento diferente los lunes y los jueves, con respecto al resto de la semana. Estudian valores comprendidos entre julio de 1997 y marzo de 2004.

Por su parte, García Blandón (2008) también encuentra efecto fin de semana, al introducir variables ficticias en una regresión que tiene como variable dependiente el rendimiento diario del IBEX-35. Este autor comprueba, analizando datos comprendidos entre enero de 1995 y mayo de 2006, que mientras el rendimiento de los lunes, martes, miércoles y jueves, no afecta de manera significativa al rendimiento del siguiente día, “el rendimiento del mercado durante el viernes, si afecta de manera importante al rendimiento del mercado del lunes siguiente”.

Si bien en esta tesis se han aplicado modelos periódicos, que permiten que cada día tenga un comportamiento diferente, no se ha relacionado este hecho con el efecto día de la semana.

Una extensión a este trabajo, es comprobar, con la realización de contrastes

formales sobre los modelos periódicos en forma VECM, como se relaciona la distinta dinámica de cada día, con el efecto día de la semana encontrado por algunos autores en la literatura.

Algunos autores justifican la existencia de estos efectos día de la semana como una muestra de falta de eficiencia en los mercados. Peña (1995) en su trabajo defiende que la mejora de la eficiencia del mercado, con la introducción de la Ley del Mercado de Valores, elimina el efecto día de la semana. Sin embargo esto es sólo cierto para la muestra que estudia, ya que se ha visto, que posteriormente, vuelve a surgir el efecto día de la semana para esos mismos valores.

Más recientemente, y usando series no españolas, Doyle y Chen (2009) estudian 13 índices bursátiles de EEUU, Japón, Alemania, Reino Unido, Francia y Hong Kong, y comprueban la existencia de efectos día de la semana. Los autores defienden que este efecto es un reto para la hipótesis de eficiencia en los mercados.

En esta tesis la detección de gran cantidad de modelos periódicos al analizar series de cotizaciones, constituye también una evidencia empírica importante en contra del paseo aleatorio como proceso generador de las series de precios en mercados eficientes.

Samuelson (1965) fue el primero que aplicó la hipótesis del paseo aleatorio a los mercados financieros, señalando que si estos fueran eficientes, los precios no se podrían prever, ya que éstos incorporan las expectativas y la información de todos los agentes que participan en el mercado.

Fama (1970) resume la anterior idea como hipótesis de eficiencia de los mercados, según la cual, los precios de los activos incorporan toda la información disponible. Por lo tanto, cuanto más eficiente sea un mercado, menos posibilidades de sacar provecho de la información adicional habrá y por tanto menos predecibles serán los precios.

Uniando las dos ideas, y en un contexto de neutralidad al riesgo, se llega a la conclusión de que si el mercado financiero es eficiente, entonces los valores bursátiles

deben seguir un paseo aleatorio, es decir, es imposible predecir sus valores futuros.

Sin embargo, en Lo y MacKinlay (1999) aparecen varias situaciones donde no se da esta equivalencia. Los anteriores autores señalan el trabajo de Lucas (1978) donde se observa que la hipótesis del paseo aleatorio no es ni condición necesaria, ni condición suficiente para la existencia de eficiencia en los mercados. En este trabajo construye ejemplos de mercados eficientes desde el punto de vista informativo, donde los precios no siguen paseos aleatorios.

La evidencia empírica sugiere que los precios de las acciones estudiadas no siguen paseos aleatorios. Aún más, es posible que existan “efectos lunes”, “efectos viernes”, “efectos miércoles”, etc, de los que se ha hablado mucho en la literatura. ¿Qué implicaciones tiene la evidencia empírica encontrada en esta Tesis sobre la supuesta eficiencia de los mercados bursátiles? Esta pregunta queda abierta para una futura investigación.

Bibliografía

- ARMSTRONG, J. S. (2001): “Evaluating Forecasting Methods,” in *Principles of Forecasting: A Handbook for Researchers and Practitioners*, ed. by J. S. Armstrong. Kluwer Academic Publishers.
- ARMSTRONG, J. S., AND F. COLLOPY (1992): “Error measures for generalizing about forecasting methods: Empirical comparisons,” *International Journal of Forecasting*, 8(1), 69–80.
- ARMSTRONG, J. S., AND R. FILDES (1995): “On the Selection of Error Measures for Comparisons Among Forecasting Methods,” *Journal of Forecasting*, 4(1), 67–71.
- BACON, D. W., AND D. G. WATTS (1971): “Estimating the transition between two intersecting straight lines,” *Biometrika*, 58(3), 525–534.
- BEAUDRY, P., AND G. KOOP (1993): “Do recessions permanently change output?,” *Journal of Monetary Economics*, 31(2), 149–163.
- BOERO, G., AND E. MARROCU (2002): “The Performance of Non-linear Exchange Rate Models: A Forecasting Comparison,” *Journal of Forecasting*, 21(7), 513–542.
- BRADLEY, M. D., AND D. W. JANSEN (2004): “Forecasting with a nonlinear dynamic model of stock returns and industrial production,” *International Journal of Forecasting*, 20(2), 321–342.
- BREDIN, D., S. HYDE, AND G. O’REILLY (2008): “Regime changes in the relationship between stock returns and the macroeconomy,” Discussion paper.

- CACERES APLINARIO, R. M., M. S. O., AND L. JORDÁN SALES (2006): “Day of the Week Effect on European Stock Markets,” *International Research Journal of Finance and Economics*, (2), 53–70.
- CLEMENTS, M. P., AND D. F. HENDRY (1993): “On the limitations of comparing mean square forecast errors,” *Journal of Forecasting*, 12(8), 617–637.
- CLEMENTS, M. P., AND H.-M. KROLZIG (1998): “A comparison of the forecast performance of Markov-switching and threshold autoregressive models of US GNP,” *Econometrics Journal*, 1(Conference), 47–75.
- DACCO, R., AND S. SATCHELL (1999): “Why do Regime-switching Models Forecast so Badly?,” *Journal of Forecasting*, 18, 1–16.
- DELL’AQUILA, R., AND E. RONCHETTI (2004): “Robust tests of predictive accuracy,” *Metron - International Journal of Statistics*, 0(2), 161–184.
- DIEBOLD, F. X., AND R. S. MARIANO (1995): “Comparing Predictive Accuracy,” *Journal of Business and Economic Statistics*, 13(3), 253–263.
- DOYLE, J. R., AND C. H. CHEN (2009): “The wandering weekday effect in mayor stock markets,” *Journal of Banking and Finance*, (33), 1388–1399.
- ENDERS, W., AND C. W. J. GRANGER (1998): “Unit-Root Tests and Asymmetric Adjustment with an Example Using the Term Structure of Interest Rates,” *Journal of Business & Economic Statistics*, 16(3), 304–311.
- ENDERS, W., AND R. PASCALAU (2010): “Pretesting the out-of-sample forecasting properties of STAR models,” .
- ENGLE, R. F., AND C. W. J. GRANGER (1987): “Co-integration and Error Correction: Representation, Estimation, and Testing,” *Econometrica*, 55(2), 251–276.
- FAMA, E. F. (1970): “Efficient Capital Markets: A Review of Theory and Empirical Work,” *Journal of Finance*, 25(2), 383–417.

- FLORES, R., AND A. NOVALES (1997): "A general test for univariate seasonality," *Journal of Time Series Analysis*, 18(1), 29–48.
- FRANSES, P. H. (1994): "A multivariate approach to modeling univariate seasonal time series," *Journal of Econometrics*, 63(1), 133–151.
- FRANSES, P. H., AND G. ROMIJN (1993): "Periodic integration in quarterly UK macroeconomic variables," *International Journal of Forecasting*, 9(4), 467–476.
- GARCÍA BLANDÓN, J. (2008): "Rendimientos estacionales en la Bolsa española: Importancia del tamaño de la empresa," *Revista Española de Financiación y Contabilidad*, XXXVII(139), 527–540.
- GRANGER, C., AND T. TERÄSVIRTA (1991): "Experiments in modeling nonlinear relationships between time series," in *Nonlinear Modeling and Forecasting*, ed. by M. Casdagli, and S. Eubank, pp. 189–197. Addison-Wesley, Redwood City, 2nd edn.
- HAMILTON, J. D. (1989): "A New Approach to the Economic Analysis of Nonstationary Time Series and the Business Cycle," *Econometrica*, 57(2), 357–384.
- HAMILTON, J. D. (2008): "Regime-Switching Models," in *New Palgrave Dictionary of Economics*, ed. by S. Durlauf, and L. Blume. Palgrave MacMillan Ltd, 2nd edn.
- HASSANI, H., S. HERAVI, AND A. ZHIGLJAVSKY (2009): "Forecasting European industrial production with singular spectrum analysis," *International Journal of Forecasting*, 25(1), 103 – 118.
- HENRY, O. T., N. OLEKALNS, AND P. M. SUMMERS (2001): "Exchange Rate Instability: A Threshold Autoregressive Approach," *The Economic Record*, 77(237), 160–166.
- HERWARTZ, H. (1997): "Performance of periodic error correction models in forecasting consumption data," *International Journal of Forecasting*, 13(3), 421 – 431.

- HYNDMAN, R. J., AND A. B. KOEHLER (2005): “Another Look at Measures of Forecast Accuracy,” Monash Econometrics and Business Statistics Working Papers 13/05, Monash University, Department of Econometrics and Business Statistics.
- JOHANSEN, S., AND K. JUSELIUS (1990): “Maximum Likelihood Estimation and Inference on Cointegration—With Applications to the Demand for Money,” *Oxford Bulletin of Economics and Statistics*, 52(2), 169–210.
- KILIAN, L., AND M. P. TAYLOR (2003): “Why is it so difficult to beat the random walk forecast of exchange rates?,” *Journal of International Economics*, 60(1), 85–107.
- KOEHLER, A. (2001): “The asymmetry of the sAPE measure and other comments on the M3-Competition,” *International Journal of Forecasting*, 17, 537–584.
- KROLZIG, H.-M. (2000): “Predicting Markov-Switching Vector Autoregressive Processes,” *Framework*, pp. 1–30.
- LÖF, M., AND P. H. FRANSES (2001): “On forecasting cointegrated seasonal time series,” *International Journal of Forecasting*, 17(4), 607 – 621.
- LO, A. W., AND A. C. MACKINLAY (1999): *A Non-Random Walk Down Wall Street*. Princeton University Press.
- LÜTKEPOLT, H. (1993): *Introduction to multiple time series analysis*. Berlin, Springer.
- LUCAS, ROBERT E, J. (1978): “Asset Prices in an Exchange Economy,” *Econometrica*, 46(6), 1429–1445.
- MAKRIDAKIS, S. (1993): “Accuracy measures: theoretical and practical concerns,” *International Journal of Forecasting*, 9(4), 527–529.
- MAKRIDAKIS, S., A. ANDERSEN, R. CARBONE, R. FILDES, M. HIBON, R. LEWANDOWSKI, J. NEWTON, E. PARZEN, AND R. WINKLER (1982): “The accu-

- racy of extrapolation (time series) methods: Results of a forecasting competition,” *Journal of Forecasting*, 1(2), 111–153.
- MARCELLINO, M. (2002): “Instability and Non-Linearity in the EMU,” CEPR Discussion Papers 3312, C.E.P.R. Discussion Papers.
- MARCELLINO, M. (2004): “Forecasting EMU macroeconomic variables,” *International Journal of Forecasting*, 20(2), 359–372.
- MARTÍNEZ ABASCAL, E. (1993): *Eficiencia Débil del Mercado Bursatil Español y Comparaciones Internacionales*. Bolsa de Madrid.
- MCCRACKEN, M. W. (2007): “Asymptotics for out of sample tests of Granger causality,” *Journal of Econometrics*, 140(2), 719–752.
- MONTGOMERY, A., V. ZARNOWITZ, R. TSAY, AND G. TIAO (1998): “Forecasting the U.S. Unemployment Rate,” *Journal of the American Statistical Association*, 93, 478–493.
- NOVALES, A., AND R. FLORES (1997): “Forecasting with periodic models A comparison with time invariant coefficient models,” *International Journal of Forecasting*, 13(3), 393–405.
- OSBORN, D., A. CHUI, J. SMITH, AND C. BIRCHENHALL (1988): “Seasonality and the Order of Integration for Consumption,” *Oxford Bulletin of Economics and Statistics*, 50(4), 361–377.
- OSBORN, D. R. (1988): “Seasonality and Habit Persistence in a Life Cycle Model of Consumption,” *Journal of Applied Econometrics*, 3(4), 255–266.
- OSBORN, D. R. (1991): “The implications of periodically varying coefficients for seasonal time-series processes,” *Journal of Econometrics*, 48(3), 373–384.
- OSBORN, D. R., AND J. P. SMITH (1989): “The Performance of Periodic Autoregressive Models in Forecasting Seasonal UK Consumption,” *Journal of Business & Economic Statistics*, 7, 117–127.

- PAYA, I., I. A. VENETIS, AND D. A. PEEL (2003): "Further Evidence on PPP Adjustment Speeds: the Case of Effective Real Exchange Rates and the EMS," *Oxford Bulletin of Economics and Statistics*, 65(4), 421–437.
- PEÑA, J. I. (1995): "Daily seasonalities and stock market reforms in Spain," *Applied Financial Economics*, 5(6), 419–423.
- PHILLIPS, P. C. B., AND S. OULIARIS (1990): "Asymtotic Properties of Residual Based Tests for Cointegration," *Econometrica*, 58(1), 165–193.
- RODRIGUES, P. M., AND P. M. GOUVEIA (2004): "An application of PAR models for tourism forecasting," *Tourism Economics*, 10, 45–92.
- RUBIO, G. (1991): "The Stock Market in Spain: Performance, Structure and the Behavior of Asset Prices," *Journal of Financial Markets and Portfolio Management*, 3, 281–303.
- SAMUELSON, P. A. (1965): "Proof That Properly Anticipated Prices Fluctuate Randomly," *Industrial Management Review*, 6(2), 41–49.
- SILIVERSTOVS, B., AND D. VAN DIJK (2003): "Forecasting Industrial Production with Linear, Nonlinear, and Structural Change Models," .
- STOCK, J. H., AND M. W. WATSON (1999): "A Comparison of Linear and Nonlinear Univariate Models for Forecasting Macroeconomic Time Series," in *Cointegration, causality and forecasting. A festschrift in honour of Clive W.J. Granger*, ed. by R. Engle, and H. White, pp. 1–44. Oxford University Press.
- TERÄSVIRTA, T. (2006): "Forecasting economic variables with nonlinear models," in *Handbook of Economic Forecasting*, ed. by G. Elliott, C. Granger, and A. Timmermann, chap. 8, pp. 413–457. Elsevier.
- TERÄSVIRTA, T., AND H. M. ANDERSON (1992): "Characterizing Nonlinearities in Business Cycles Using Smooth Transition Autoregressive Models," *Journal of Applied Econometrics*, 7(S), 119–136.

- TERÄSVIRTA, T., AND A.-C. ELIASSON (2001): “Non-linear error correction and the UK demand for broad money, 1878-1993,” *Journal of Applied Econometrics*, 16(3), 277–288.
- TERÄSVIRTA, T., D. VAN DIJK, AND M. C. MEDEIROS (2005): “Linear models, smooth transition autoregressions, and neural networks for forecasting macroeconomic time series: A re-examination,” *International Journal of Forecasting*, 21(4), 755–774.
- TIAO, G. C., AND M. R. GRUPE (1980): “Hidden periodic autoregressive-moving average models in time series data,” *Biometrika*, 67(2), 365–373.
- WELLS, J. (1997a): “Modelling seasonal patterns and long-run trends in U.S. time series,” *International Journal of Forecasting*, 13(3), 407 – 420.
- WELLS, J. M. (1997b): “Business Cycles, Seasonal Cycles, and Common Trends,” *Journal of Macroeconomics*, 19(3), 443–469.

